


Fundación Universidad del Norte

MODELO DE DIAGNÓSTICO DE CONDUCCIÓN ERRÓNEA BASADO EN LA INFORMACIÓN DE LA COMPUTADORA DEL VEHÍCULO PARA LA CARACTERIZACIÓN DEL COMPORTAMIENTO DEL CONDUCTOR

TESIS DE MAESTRÍA

Diego Gómez Cerón



**MODELO DE DIAGNÓSTICO DE CONDUCCIÓN ERRÓNEA BASADO EN LA
INFORMACIÓN DE LA COMPUTADORA DEL VEHÍCULO PARA LA
CARACTERIZACIÓN DEL COMPORTAMIENTO DEL CONDUCTOR**

PRESENTADO A LA DIVISIÓN DE INGENIERÍAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
FUNDACIÓN UNIVERSIDAD DEL NORTE

PARA LA OBTENCIÓN DEL TÍTULO DE
MAGISTER EN INGENIERÍA ELECTRÓNICA

POR

DIEGO FERNANDO GÓMEZ CERÓN
INGENIERO ELECTRÓNICO

TRABAJO ASESORADO POR:
PhD. CHRISTIAN G. QUINTERO M.

Barranquilla, Julio de 2011

Tabla de contenido

LISTA DE ILUSTRACIONES	5
LISTA DE TABLAS	6
1 INTRODUCCIÓN	7
1.1 MOTIVACIÓN	7
1.2 OBJETIVOS	8
1.3 JUSTIFICACIÓN	8
2 MARCO TEÓRICO Y TRABAJOS RELACIONADOS	10
2.1 SISTEMAS DE SEGURIDAD DISPONIBLES EN EL MERCADO	10
2.2 MANEJO SEGURO	12
2.3 MODELOS	13
2.3.1 <i>Dinámica del Vehículo</i>	13
2.3.2 <i>Comportamiento del Conductor</i>	14
2.4 ADQUISICIÓN DE SEÑAL	15
2.4.1 <i>Métodos de detección</i>	15
2.4.2 <i>Sensores</i>	16
2.4.3 <i>Buses y protocolos</i>	17
2.5 TÉCNICAS DE PROCESAMIENTO	18
2.5.1 <i>IA</i>	18
2.5.2 <i>Control Clásico</i>	21
2.6 VALIDACIÓN	21
2.6.1 <i>Simuladores</i>	21
2.6.2 <i>Plataformas reales</i>	23
2.7 TENDENCIAS	24
2.8 DISCUSIÓN SOBRE LA REVISIÓN	26
3 DESCRIPCIÓN GENERAL DE LA PROPUESTA	27
3.1 DIAGRAMA DE BLOQUES	29
3.1.1 <i>Pre-procesamiento (Pre-processing)</i>	29
3.1.2 <i>Determinación del comportamiento del conductor (Driver Behavior)</i>	30
3.1.3 <i>Aprendizaje Continuo (Continuous Learning)</i>	31
3.1.4 <i>Reconocimiento del Conductor (Driver Recognition)</i>	31
3.1.5 <i>Clasificador de Condiciones Anormales de Manejo (Abnormal Condition Classifier)</i>	32

3.2	DIAGRAMA DE FLUJO.....	33
4	DESCRIPCIÓN DE LA HERRAMIENTA DE SIMULACIÓN - EDDSYSTEM	35
4.1	VARIABLES DE ENTRADA.....	35
4.2	SIMULADOR DE REALIDAD VIRTUAL - RACER	36
4.3	DIAGRAMA GENERAL.....	38
4.4	SISTEMA DE DIAGNÓSTICO.....	40
4.4.1	<i>Subsistema para Diagnóstico de Posición</i>	<i>43</i>
4.4.2	<i>Subsistema para Diagnóstico de Excesos de Velocidad</i>	<i>43</i>
4.4.3	<i>Subsistema para Diagnóstico de Cambios Bruscos en el Volante</i>	<i>44</i>
4.4.4	<i>Subsistema para Diagnóstico de Cambios Bruscos en los Pedales.....</i>	<i>45</i>
4.4.5	<i>Red de Diagnóstico General.....</i>	<i>45</i>
5	DISEÑO DE EXPERIMENTOS Y VALIDACIÓN DEL MODELO PROPUESTO	47
5.1	ESPECIFICACIONES DE DISEÑO	47
5.1.1	<i>Problemática</i>	<i>49</i>
5.1.2	<i>Solución: Método de Inversión.....</i>	<i>54</i>
5.2	EVOLUCIÓN DEL CONDUCTOR	58
5.3	ADAPTABILIDAD DEL CONDUCTOR.....	62
5.4	CONTRASTE ENTRE CONDUCTORES.....	65
5.5	ALTERACIONES DE CONCIENCIA (DISTRACCIÓN Y SUEÑO).....	70
5.6	MAPA DE RIESGO DE LA CARRETERA.....	72
6	CONCLUSIONES	77
7	TRABAJO FUTURO	81
8	GLOSARIO	82
9	BIBLIOGRAFÍA.....	85

Lista de Ilustraciones

ILUSTRACIÓN 1. SISTEMA DE DETECCIÓN DE CONDUCTORES SOMNOLIENTOS USANDO REDES NEURONALES ARTIFICIALES.	20
ILUSTRACIÓN 2. ARQUITECTURA DEL SISTEMA FUNCIONAL PROPUESTO.....	29
ILUSTRACIÓN 3. DIAGRAMA DE FLUJO DEL PLANTEAMIENTO PROPUESTO	33
ILUSTRACIÓN 4. RACER: PLATAFORMA DE SIMULACIÓN PARA LA CONDUCCIÓN DE AUTOMÓVILES.....	36
ILUSTRACIÓN 5. INTERACCIÓN DE MATLAB CON EL SIMULADOR.	38
ILUSTRACIÓN 6. DIAGRAMA GENERAL DEL SISTEMA DE DIAGNÓSTICO.....	39
ILUSTRACIÓN 7. PARÁMETROS PARA EJECUCIÓN DEL SIMULADOR DE CONDUCCIÓN.....	41
ILUSTRACIÓN 8. DIAGNÓSTICO DEL EDDSYSTEM.	42
ILUSTRACIÓN 9. ANÁLISIS DE <i>ASPECTOS ESPECÍFICOS</i> DEL EDDSYSTEM.	42
ILUSTRACIÓN 10. CÁLCULO DE LOS DATOS DE ENTRADA PARA LA RED DE POSICIÓN.	43
ILUSTRACIÓN 11. TRANSFORMADA DE FOURIER DE LA SEÑAL DEL ÁNGULO DE GIRO DEL VOLANTE.....	45
ILUSTRACIÓN 12. DIAGNÓSTICOS IDEALES.....	51
ILUSTRACIÓN 13. EJEMPLO DE DIAGNÓSTICO VS NÚMERO DE RECORRIDOS	54
ILUSTRACIÓN 14. MÉTODO DE INVERSIÓN PARA DIAGNÓSTICO IDEAL NORMALIZADO A PARTIR DE DISTINTOS RECORRIDOS.	56
ILUSTRACIÓN 15. VARIACIÓN DEL DESEMPEÑO NORMALIZADO.	57
ILUSTRACIÓN 16. EVOLUCIÓN DE DESEMPEÑO NORMALIZADO DEL CASO REAL EXHIBIDO EN LA ILUSTRACIÓN 13.....	57
ILUSTRACIÓN 17. GRÁFICO DE DE EVOLUCIÓN DE CONDUCCIÓN PARA LUIS SEVERICHE.	60
ILUSTRACIÓN 18. EVOLUCIÓN DE DESEMPEÑO PARA LUIS SEVERICHE	60
ILUSTRACIÓN 19. CONDUCTORES QUE HAN EVOLUCIONADO SEGÚN LA CANTIDAD DE RECORRIDOS.....	62
ILUSTRACIÓN 20. INTERVALO DE CONFIANZA SEGÚN EL RECORRIDO ESCOGIDO COMO TRANSICIÓN	62
ILUSTRACIÓN 21: PUNTOS DE CONTROL DEFINIDOS PARA CADA PISTA PARA CONSTRUIR SU MAPA DE RIESGO	73

Lista de Tablas

TABLA 1. EJEMPLO APLICACIÓN DEL MÉTODO DE INVERSIÓN A PARTIR DE DIFERENTES RECORRIDOS.....	55
TABLA 2. DATOS DE EVOLUCIÓN DE CONDUCCIÓN PARA LUIS SEVERICHE.	59
TABLA 3: RECORRIDO DE TRANSICIÓN Y NIVEL DE ESTABILIZACIÓN DE CADA CONDUCTOR EN CADA PRUEBA.....	60
TABLA 4: RECORRIDO DE TRANSICIÓN Y NIVEL DE ESTABILIZACIÓN DE CADA CONDUCTOR EN CADA PRUEBA.....	62
TABLA 5: RECORRIDO DE ADAPTACIÓN Y NIVEL DE ESTABILIZACIÓN EN CADA PRUEBA DE ADAPTACIÓN.....	64
TABLA 6: RECORRIDO DE ADAPTACIÓN Y NIVEL DE ESTABILIZACIÓN POR CONDUCTOR PARA AFINAMIENTO.	65
TABLA 7: CÓDIGO DE CATEGORÍAS PROPUESTAS PARA EL MCC.	67
TABLA 8: EJEMPLO DE CONTRASTE ENTRE CONDUCTORES.	68
TABLA 9: CATEGORÍAS ASIGNADAS A LOS CONDUCTORES LUEGO DE APLICAR EL MCC.....	68
TABLA 10: CONTRASTE ENTRE CONDUCTORES PARA EL PLANTEAMIENTO DE LA HIPÓTESIS.....	70
TABLA 11. DIAGNÓSTICOS OBTENIDOS SEGÚN ALTERACIÓN DE CONCIENCIA PARA MARÍA SEVERICHE.	71
TABLA 12: CÁLCULO DE LA SUMATORIA PONDERADA DE LAS ZONAS DE PISTA “BADLANDS” SEGÚN MCP.....	75
TABLA 13: CÁLCULO DE LA SUMATORIA PONDERADA DE LAS ZONAS DE PISTA “CARLSWOOD” SEGÚN MCP.....	75
TABLA 14: CÁLCULO DE LA SUMATORIA PONDERADA DE LAS ZONAS DE PISTA “THE RIVER” SEGÚN MCP.....	76
TABLA 15: EJEMPLO DE DIAGNÓSTICOS POR ZONAS DE “CARLSWOOD” PARA DIFERENTES RECORRIDOS.	76

1 INTRODUCCIÓN

1.1 MOTIVACIÓN

La principal motivación de esta Tesis es desarrollar un modelo que permita un diagnóstico sobre las condiciones en que maneja un conductor, tendiente a hacer parte de un sistema de seguridad pasiva a ser incluido de manera masiva en automóviles con menos de quince años de antigüedad. Y aunque hoy en día resulta inminente la participación de la electrónica en las etapas de diseño de cada modelo concebido por la industria automotriz, siendo uno de los principales objetivos de los diseñadores el hacer vehículos cada vez más seguros; dichos sistemas se limitan al contexto exterior del auto y no supervisan al conductor mismo, quien puede encontrarse en condiciones no aptas para el manejo como lo son el cansancio extremo o la influencia de drogas o alcohol.

Entre el 70 y el 90% de la accidentalidad vial se debe a comportamientos inseguros de las personas debido a alteraciones psicofísicas transitorias o estados de modificación de la conducta que alteran la aptitud del conductor [1]. Dentro de estos comportamientos están: la fatiga, la distracción, el sueño, la ira, el estrés, la depresión y la ansiedad [1]. Independientemente de la condición en que se encuentre el conductor, uno de los logros de este trabajo es el haber podido caracterizar este tipo de comportamientos a partir del diagnóstico de maniobras de conducción errónea, las cuales comprenden el superar velocidades máximas, salirse del carril o de la carretera y movimientos bruscos en el volante, acelerador o el freno. Es claro que controlar cada una de estas causas de accidentalidad desde el interior de un automóvil puede llegar a ser muy difícil para sistemas de detección visual, debido a la gran variedad de las posibilidades [2]. Sin embargo, puede generarse una solución al diagnóstico de dichas maniobras de conducción, mediante el procesamiento y análisis inteligente de las señales ofrecidas por la computadora del vehículo [3].

Este trabajo muestra que es posible la identificación de un estado de conducción errónea mediante un modelo basado en técnicas de IA, con la información de sensores ya instalados en el vehículo, como por ejemplo, aquéllos pertinentes al control de emisión de gases impuestos por normatividad de tipo ambiental. El conjunto de dichas variables ha sido contrastado con un patrón de condiciones normales para manejo, característico para cada individuo, formado por valores propios para cada variable sensada y actualizable de manera adaptativa.

1.2 OBJETIVOS

El objetivo principal de esta Tesis es modelar y validar un sistema de diagnóstico de manejo erróneo. Para lograrlo, se han definido los siguientes objetivos específicos:

- Identificar y caracterizar el conjunto de variables que servirán como entrada al sistema de diagnóstico
- Implementar un aprendizaje (adaptativo) para el patrón de condiciones normales para manejo.
- Determinar la(s) técnica(s) más adecuada(s) de soft computing para la implementación del sistema de diagnóstico.
- Modelar y validar el sistema de diagnóstico ante diversas condiciones para el conductor y para el entorno del vehículo.
- Simular el modelo

1.3 JUSTIFICACIÓN

Estudios alrededor del mundo estiman que entre el 24% y el 33% de los accidentes fatales se vieron involucrados conductores con cansancio extremo, siendo esta la principal causa de accidentalidad en el antiguo continente. Estas cifras motivan programas de prevención, como el “eSafety”¹, de Daimler, que apoya desarrollos de seguridad activa en busca de reducir el número de víctimas fatales en accidentes. El Fondo de Prevención Vial en su Informe sobre Accidentalidad Vial² consolida cifras estadísticas para los accidentes ocurridos en las carreteras (fuera de las urbes) colombianas en los últimos diecisiete años. Aunque a la conducción bajo efectos del alcohol o drogas se le atribuye el 5.4% de los accidentes, no hay información sobre aquellos asociados con cansancio o sueño por parte del conductor.

En la actualidad, un sistema inteligente para la identificación del manejo erróneo puede ser una alternativa adecuada para proveer de mayor seguridad a conductores y peatones[4]. Por tal motivo, se plantea el diseño de un sistema que permita un reconocimiento de una condición

¹ Disponible on-line en <http://media.daimler.com>

² Disponible on-line en <http://fonprevial.org.co>

anormal de manejo en función del comportamiento del conductor, las variables del entorno del auto y demás información registrada en datos históricos; adquiriendo y aplicando todo este conocimiento de una manera inteligente. Para tal fin, se estudiará(n) y seleccionará(n) la(s) técnica(s) más adecuada(s) de soft computing para la implementación de un sistema capaz de emitir un diagnóstico de manejo erróneo.

Con el diseño, modelamiento y simulación del sistema en mención, que operará bajo la técnica escogida, se debe obtener una base para el desarrollo de una plataforma cuya implementación a futuro favorezca a cada uno de los entes que participan como usuarios o administradores de las vías. Una plataforma informática capaz de dar información en tiempo real a las autoridades sobre el estado de las vías y la presencia en ella de conductores no deseados, para poder tomar decisiones inmediatas tales como la actualización de la señalización y la interceptación de estos individuos. Además, con las posibilidades de centralizar la información para su registro y consulta remota por dueños de vehículos, transportistas, reguladores de tránsito, legisladores y conductores corrientes.

La propuesta tendrá impacto científico, tecnológico y social. El primero de ellos se fundamenta en la elección de la técnica, o conjunto de ellas, que determinen la elaboración de un sistema que sea capaz de percibir, razonar, aprender y tomar decisiones a partir de información del vehículo y su entorno. La selección debe fortalecer el Sistema de Telemetría para la Gestión del Transporte Público Urbano (STGTPU) desarrollado por el Grupo de Investigación de Telecomunicaciones y Señales en Uninorte. De otro lado, el impacto tecnológico radica en la innovación que conlleva una plataforma de seguridad activa cuya atención se centra directamente sobre el conductor, pues ahora no sólo se toma una acción sobre el mismo sino que se toma constante información de sus acciones sobre el vehículo. En la actualidad, dichos sistemas sólo dependen de información del vehículo y de su entorno, mas no del usuario.

Finalmente, el impacto social se espera al poder ofrecer un sistema que ayude a reducir los índices de accidentalidad vehicular mediante la toma de decisiones certeras que aminoren o eviten las víctimas fatales en siniestros viales.

2 MARCO TEÓRICO Y TRABAJOS RELACIONADOS

El desarrollo de un sistema de diagnóstico de manejo erróneo basado en técnicas de inteligencia computacional comprende un estudio de los trabajos relacionados en diferentes áreas. Inicialmente, se presentan las nociones referentes a los sistemas de seguridad que ofrece un vehículo comercial, sus debilidades y las soluciones propuestas por algunos autores. Seguidamente, para poder realizar un diagnóstico es necesario conocer las diferentes técnicas propuestas para mantener la seguridad en las carreteras y los modelos para recrear la dinámica del vehículo. El correcto procesamiento de la información implica un análisis de las técnicas disponibles para adquisición de datos, transmisión de la información, enfoques inteligentes como solución a problemas en sistemas de transporte y las diferentes plataformas de simulación y reales para la validación de la información. Por último, se concluye con las últimas tendencias de sistemas inteligentes de asistencia vehicular.

2.1 SISTEMAS DE SEGURIDAD DISPONIBLES EN EL MERCADO

Fuera de los conceptos relacionados con las técnicas de Inteligencia Artificial que resultan hoy en día más relevantes, como lo son la lógica difusa, las redes neuronales, los algoritmos genéticos y el razonamiento basado en casos; el lector debe familiarizarse con nociones referentes a los sistemas de seguridad que ofrece un vehículo comercial hoy en día.

Seguridad Pasiva

Hace referencia a sistemas que actúan durante el impacto del vehículo y buscan reducir las lesiones provocadas durante el accidente, tanto al conductor como al peatón. Dentro de esta clasificación se encuentran los cinturones de seguridad, los apoyos cabezas, las barras laterales, los airbag y todo tipo de estructuras de absorción de impacto en la carrocería.

Seguridad Activa

Los sistemas de seguridad activa buscan disminuir el riesgo de una posible colisión mediante la anticipación del evento, dotando al conductor de una mayor maniobrabilidad del vehículo durante condiciones adversas de manejo. Sistemas electrónicos como el ABS (Antilock Break System), EPS (Electronic Power Steering), ESP® (Electronic Stability Program), EBD (Electronic Break

Distribution), Pre-Safe Brake Assist Plus®, entre otros; son hoy concebidos como una solución de seguridad activa para vehículos y constituyen el principal respaldo ante posibles alteraciones en el entorno del vehículo.

En la actualidad, algunos vehículos de alta gama se encuentran dotados con sistemas de asistencia al conductor en la vía, tales como:

- Control de Crucero Adaptable (ACC - Adaptive Cruise Control): Es un sistema que permite programar una velocidad máxima a la que el vehículo llega de manera automática, y que se mantiene sostenida una vez alcanzada. Cuando el vehículo delantero disminuye la velocidad, el ACC también lo hace respetando un margen de distancia de seguridad.
- Asistencia de Frenada de Pre-colisión (Collision Avoidance): Es un sistema capaz de detectar la cercanía de un obstáculo frontal. El sistema pone en advertencia al conductor de la situación de peligro y, ante un inminente riesgo de colisión, activa los frenos de manera automática.
- Sistema para anti-bloqueo de frenado (ABS - Antilock Break System): Es un sistema que ejerce múltiples activaciones del freno en franjas de tiempo del orden de milisegundos, con el fin de garantizar un mayor coeficiente de fricción entre la llanta y el pavimento al renovar la superficie de contacto entre cada activación.
- EBD (EBD - Electronic Brakeforce Distribution): Es un sistema de asistencia al frenado que, trabajando con el ABS, ofrece la posibilidad de distribuir de manera independiente la acción de frenado sobre cada rueda acorde con las condiciones del terreno, la velocidad del vehículo y la carga del motor. El sistema busca mitigar las posibilidades de que el vehículo se deslice (patine) si control.
- Control de Tracción: Es un sistema que previene el deslizamiento no deseado en las llantas cuando estas pierden adherencia por la demanda de torque del motor. Las acciones que ejerce el sistema constan en el frenado de la llanta que patina o la disminución del torque mediante la condena del sistema de combustión del motor.
- Control de Estabilidad (ESP - Electronic Stability Program): Hace referencia a la plataforma compuesta por los tres últimos sistemas mencionados (ABS, EBD y)

Una problemática común a los sistemas anteriormente mencionados se encuentra en la aceptación de los mismos por parte del conductor [5]. Las acciones que se toman de manera automática deben estar acorde con el criterio de cada conductor. De no hacerlo, el sistema puede llegar a incomodar, aturdir, distraer o enfurecer al conductor. De ahí la importancia de trabajar en el levantamiento de patrones de conducción totalmente personalizados que, implementados en conjunto con estos sistemas, sean capaces de ejecutar acciones más acorde a como lo haría el conductor sin el sistema de asistencia.

2.2 MANEJO SEGURO

Son varias las técnicas propuestas para mantener la seguridad en las carreteras. Algunas se limitan a ser aproximaciones de un modelo validado mediante simulación, y otras llegan a ofrecer incluso un planteamiento respaldado por una implementación real. Según Kumamoto [4], estas técnicas se podrían clasificar en aquellas que consideran:

- Información interna del vehículo
- Información asociada al estudio facial o corporal (movimientos de cabeza o pies) del conductor
- Información del entorno del vehículo (peatones, obstáculos, vehículos próximos y señalización de la carretera)

El fin último de cualquier sistema de asistencia al conductor va dirigido a la reducción del número de accidentes de tráfico o la mitigación del daño ante un inminente accidente. BISHOP [6] presenta los diferentes objetivos de seguridad en carreteras manifiestos para diferentes países, ofreciendo una perspectiva global de las tendencias de sistemas electrónicos de asistencia y confort, por las que se han de regir fabricantes de vehículos livianos y pesados en Asia, Europa y Norteamérica.

En los trabajos relacionados con el tema resulta interesante conocer enfoques cognoscitivos para caracterizar el comportamiento del conductor, tal como lo hace Kumamoto[4], clasificando toda acción en el manejo como la manifestación consciente o inconsciente de simples intenciones; que son base fundamental de un simulador para animar comportamientos grupales de varios conductores. Lattner [7] recalca la importancia de basar los sistemas de asistencia vehicular

(aquellos que se soportan en la computadora del auto) en motores de inferencia que permitan formular y ejecutar acciones basadas en el sentido común, como lo es el caso de aquellos basados en el conocimiento. Su método cualitativo se fundamenta en información cualitativa recopilada por sensores, que es procesada y almacenada como “hechos simbólicos” en la base de conocimiento.

Independientemente de la técnica para extracción de información, los métodos para identificar la falta de atención del conductor se clasifican en[8]:

- Aproximaciones sobre procesamiento de señales biológicas
- Estimaciones basadas en reportes subjetivos - Karolinska Sleepiness Scale (KSS).
- Estimaciones basadas en procesamiento de señales relacionadas al comportamiento del conductor.

Cabe anotar que sólo el último método se considera como válido para ser implementado, dentro del contexto que implica una conducción real. Los otros dos sólo son referencias teóricas para el tercero.

2.3 MODELOS

2.3.1 Dinámica del Vehículo

Guldner [9] basa su controlador en un modelo clásico de 1940, para recrear la dinámica del volante (dirección). Integrando los resultados de este modelo junto con el de una carretera con curvas a seguir, es posible tener el desplazamiento lateral y frontal del vehículo con respecto a la carretera. Con ello se logra establecer cómo interactúan la dinámica lateral y la longitudinal del vehículo.

Wewerinke [10] propone un modelo para la conducción, basado en redes neuronales, que valida en la maniobra de sobrepaso de un vehículo. El modelo considera variables externas como vehículos adyacentes, velocidad de estos y, finalmente, distancia entre el vehículo y sus vecinos. El modelo es una aproximación netamente teórica, demasiado específica, no validada en una plataforma real.

Otros trabajos, como el de Jiménez [11], se han dedicado a combinar modelos del vehículo con la geometría de la carretera, con el fin de establecer un método capaz de generar límites de velocidad variantes. Así, no sólo se puede construir un Mapa de Riesgo de la Vía, sino que se puede instalar una solución electrónica encaminada a dar aviso al conductor sobre un exceso de velocidad en determinado terreno.

2.3.2 Comportamiento del Conductor

Los modelos existentes hasta el momento para determinar el comportamiento del conductor buscan proporcionar una tecnología sostenible que puede predecir el comportamiento de algunos impedimentos como la fatiga [12][13]. Estas debilidades se atribuyen a la dependencia de los marcadores biológicos como la percepción, las características individuales de cada persona, y la ausencia de una línea de base que especifique un comportamiento normativo. Recientemente, modelos estadísticos se han utilizado para predecir el comportamiento al volante.

Sin embargo, sólo unos pocos estudios han propuesto un método para predecir el comportamiento a futuro de la conducción. KUMAGAI [13] plantea una técnica de predicción del comportamiento del conductor en el futuro próximo con una simple red bayesiana dinámica. En este estudio, ellos aplican un método propuesto para la predicción de velocidad a futuro. Especialmente, compararon dos simples redes dinámicas bayesianas: un modelo oculto de Markov (HMM) y un sistema de conmutación dinámica lineal (SLDS).

El proyecto SmartCar modela y reconoce maniobras a nivel táctico. Este utiliza modelos ocultos de Markov para predecir futuras maniobras [14]. KAMAL [5] utiliza redes Bayesianas para predecir futuras paradas del vehículo en una intersección. En otra publicación, KUMAGAI [15] también utiliza redes bayesianas para detectar comportamientos inusuales en el conductor. Redes neuronales y redes bayesianas se han utilizado para el reconocimiento de patrones de conducción a gran escala en tiempo real ante la dinámica del vehículo y sobre diferentes casos de estudio, tales como autopistas y carreteras principales [16].

Otro trabajo utiliza mediciones fisiológicas (EMG, EKG) y los algoritmos secuenciales para detectar estrés en el conductor [17] hipovigilancia [18]. El estrés, la fatiga o hipovigilancia se encuentran entre el estado cognitivo que podría influir en el comportamiento futuro de un conductor. Por lo tanto son conceptos que podrían ser incluidos como factores que influyen en el comportamiento del conductor.

2.4 ADQUISICIÓN DE SEÑAL

En resumen, la gran mayoría de desarrollos buscan recolectar información de tres fuentes: el conductor, el vehículo y el entorno del vehículo. Mohan [19] muestra un compendio de esta sensorica en un resumen de sistemas de adquisición implementados en un vehículo de prueba perteneciente a la plataforma de pruebas LISA (Laboratory for Intelligent, Safe Automobiles). No obstante, el trabajo sólo presenta la sensorica sin llevar a cabo su integración.

Desarrollos como el propuesto por Takahashi [20], plantean el uso de técnicas de Inteligencia Artificial para poder identificar potenciales situaciones de riesgo, mediante el análisis de imágenes del entorno frontal del vehículo. El objetivo es brindar una interfaz que advierta al conductor sobre riesgos potenciales en la vía, como una posible solución ante alteraciones de conciencia de este. El modelo ha sido validado con imágenes adquiridas desde maquetas en miniatura y con otras tomadas de un banco de imágenes (dataset) que ofrece este tipo de situaciones riesgosas.

2.4.1 Métodos de detección

En algunos desarrollos que estudian el nivel de sueño del conductor [21], se trabaja con la medición del índice PERCLOS (Percentage of Eye Closure), un método válido para detectar el nivel de alerta del conductor con el simple monitoreo de la caída del párpado durante un determinado tiempo.

Otros métodos combinan el modelo del vehículo con el modelo de la vía, con el fin de establecer límites variables para el conductor, acorde con las condiciones de la vía. A pesar de la gran dificultad que se presenta en el método propuesto por Jiménez [11] a la hora de medir en tiempo

real el coeficiente de fricción que presenta la carretera, el método ha sido validado bajo condiciones de manejo real, mostrando una reducción en la velocidad media en ciertas curvas cerradas y logrando incrementar la fluidez de tráfico en las zonas evaluadas.

ERDOGAN [22] trabaja con un dataset compuesto por información tal como: aceleración, freno, velocidad, RPM y ángulo del timón. Su proyecto plantea el uso de un conjunto de clasificadores GMM (Gaussian Mixture Model) para identificar el conductor del vehículo. El trabajo demuestra la robustez de emplear la combinación de clasificadores múltiples entrenables, y no fijos, logrando menores tasa de error a la hora de identificar un conductor.

2.4.2 Sensores

Cámaras de video

La gran mayoría de trabajos sobre seguridad en carreteras basan su operación en la información extraída a través de cámaras de video. Algunas sirven para monitorear al conductor mismo, en búsqueda de determinar su nivel de cansancio (o nivel de alerta) mediante la medición del índice de PERCLOS [21, 23] o mediante la detección de “cabeceos” (movimientos bruscos de la cabeza, propios del estado inicial de adormecimiento). Algunas son usadas para el monitoreo del entorno del vehículo, y se encuentran en constante vigilancia de la cercanía de objetos como vehículos vecinos y peatones, o se encuentran en estudio de las líneas de demarcación de la carretera, con el fin de detectar salidas indebidas del auto de su respectivo carril.

Las cámaras de video proporcionan información a detalle que otros métodos no intrusivos no garantizan. LINGLING [12] utiliza dos cámaras para detectar el bostezo de un conductor en estado de fatiga. Una de las cámaras se encarga de detectar la posición de la cabeza, y la otra busca localizar su boca para extraer la información requerida para la detección del bostezo. Este trabajo muestra una estrategia de interacción entre dos cámaras: una de baja resolución que reconoce un patrón genérico, para activar una segunda que busca información más específica sobre el primer patrón.

No obstante, como en toda aplicación basada en captura de imágenes, los resultados de estos desarrollos se encuentran supeditados a las condiciones de iluminación del objetivo a registrar (cara del conductor, cabeza del conductor, demarcación de la carretera, vehículos cercanos, peatones).

Radar

Otra alternativa para conocer información sobre el entorno del vehículo es la que ofrecen las señales de Radar, cuyas principales ventajas radican en la independencia de las condiciones climáticas, la posibilidad de medir directamente la velocidad y la cercanía de objetos adyacentes, y los beneficios que ofrece la medición basada en la reflexión del piso. Existen tres tipos acorde con la distancia y el ángulo de cobertura: de largo alcance (LRR - Long-Range Radar), de alcance medio (MRR - Mid-Range Radar) y de alta resolución (UWB – Ultra WideBand) [24].

El radar se consideraba como una tecnología de sensado no popularizada según lo refleja VAA [25] en una revisión del estado del arte para el año 2007. Sin embargo, la tecnología de radar se ha desarrollado a tal punto de participar en sistemas de respaldo existentes, como los de posicionamiento del vehículo. PARVIAINEN [26] expone un desarrollo mediante el cual la señal de radar se integra con la de un giroscopio para respaldar el sistema de posicionamiento ante eventuales interrupciones de la señal GPS, actuando como un GPS Diferencial - DGPS.

2.4.3 Buses y protocolos

OBD II - On Board Diagnostics (ver.II)

Es un protocolo que ofrece un diagnóstico del estado de la máquina en función de condiciones para la correcta emisión de gases. Propuesto por la EPA (Environmental Protection Agency), se exige a todo vehículo de fabricación posterior al año 96, que circule en USA. Para la presente investigación, el OBD se considera una alternativa para la extracción de variables al estar presente en varios modelos de vehículos en Colombia y al ofrecer un conector estandarizado. Se aclara que la línea de ITS del Grupo de telecomunicaciones y Señales ha adelantado dos proyectos en los que se vale de dicho estándar para la disposición de distintas variables de interés, durante la marcha del vehículo.

Bus CAN

El bus CAN es el protocolo de comunicación industrial más posicionado, desde su aparición en los 90's. Este es un protocolo controlado por eventos, en el que los mensajes se envían según su prioridad. Ofrece ventajas como reclamo de una señal ACK al destinatario, mecanismos de detección de errores, asignación de ancho de banda dinámico a los nodos, corto retardo de propagación, y topología flexible [27, 28]. No obstante, ofrece desventajas asociadas a problemas por el manejo de prioridades de los mensajes, que lo hacen un protocolo no determinístico [29].

FlexRay

Es un protocolo basado en comunicación por disparo de tiempos, determinístico, tolerante a fallos y de altas tasas de transmisión [30]. Se presenta como una alternativa mejorada al Bus CAN, cuya interacción promete posicionarse como la principal plataforma de comunicación en la industria automotriz [31]. Su robustez es objeto de estudio para su implementación en aplicaciones tan sensibles como la “Dirección sobre cables” (SBW – Steering By Wire) [30], una tendencia cuyo auge se verá con la popularización de vehículos híbridos o aquellos totalmente eléctricos.

2.5 TÉCNICAS DE PROCESAMIENTO

2.5.1 IA

Yasunobu [32] muestra la acción de parqueo de un vehículo en reversa asistida por un controlador inteligente que aprende del entorno cada que los obstáculos son actualizados en el proceso de sensado y avance del auto, actuando bajo un modelo de prueba y error basado en objetivos difusos.

En el planteamiento de Takahashi [20], se emplean redes neuronales para analizar imágenes que ofrecen escenarios de potencial de riesgo de accidentalidad. El entrenamiento de la red depende de factores como la consideración de qué es una situación de riesgo, la dirección de movimiento del objetivo en la escena, la clasificación del tipo de vía, y el nivel de importancia que asocia un conductor a determinada situación de riesgo.

Kamal [5] sugiere un modelo neuro-difuso que considera el comportamiento del conductor para determinar la acción de aceleración/frenado de un vehículo que circula por una vía, con base en su cercanía con el vehículo delantero. Lo interesante de su planteamiento se encuentra en que este tiene en cuenta parámetros estadísticos recientes del conductor, y también sus variaciones, para retroalimentar el sistema y lograr su adaptabilidad.

Chang [33] desarrolla una red neuro-difusa con el fin de atender dos problemáticas: abandono brusco de carril y choque frontal. Para cada una de las soluciones hace uso de un sistema difuso que evalúa las condiciones del entorno con el fin de determinar un umbral que afectará directamente un sistema de decisión basado en redes neuronales. La conveniencia del uso de redes neuronales radica en la complejidad matemática que implica describir las alteraciones súbitas de las variables involucradas, en los instantes previos a un abandono brusco de carril. Teniendo en cuenta que este planteamiento se re-entrena cada tercio de segundo, dando información continua sobre la conservación y abandono correctos del carril, podría ser un interesante respaldo para sistemas de diagnóstico.

Michler [34] ha trabajado en la aproximación de un sistema de diagnóstico autónomo para reemplazar la capacidad humana de diagnóstico en un examen de testeo de la durabilidad de los automóviles. Para lograr su objetivo ellos fusionaron un sistema de control del vehículo con el módulo especial de diagnóstico para la identificación de fallas, el cual fue implementado y probado con dos topologías de redes neuronales artificiales: Backpropagation (BP) y Learning Vector Quantisation (LVQ), obteniendo mejores resultados con BP.

Dentro de los trabajos desarrollados para el diagnóstico inteligente de conducción se destacan los siguientes. POMERLEAU [2], desarrolló investigaciones en tres áreas de la aplicación de redes neuronales en el dominio de vehículos inteligentes: monitoreo de videos de tráfico, monitoreo y control de las señales ofrecidas por la computadora del vehículo y el control de la visión lateral. El autor propone que por la simplicidad y uniformidad de las arquitecturas de redes neuronales y los algoritmos empleados para su funcionamiento, éstas tienen el potencial de ser implementadas eficientemente en hardware, lo cual es comercialmente viable.

PERRIER [35], utilizan un sistema neuro-simbólico para ayudar al monitoreo y diagnóstico de vehículos submarinos autónomos. El sistema neuro-simbólico (NSS) permite el trabajo simultáneo de reglas simbólicas y redes neuronales, usando transformación de técnicas.

BÜRGER [36], ha desarrollado uno de los mejores trabajos de investigación en cuanto a las tecnologías de vehículos inteligentes. Ellos proponen un sistema experto para sistemas de ayuda al conductor. Su sistema inteligente tiene un conocimiento base y procesa los datos recibidos por los sensores no sólo cuantitativamente, sino también, cualitativamente. Así también, los datos se interpretan comparando éstos con otros datos similares generados en el pasado, logrando reconocer patrones del comportamiento del conductor y del medio que le rodea. Ellos lograron detectar conductores somnolientos usando redes neuronales artificiales, utilizando la metodología que se puede observar en la Ilustración 1.

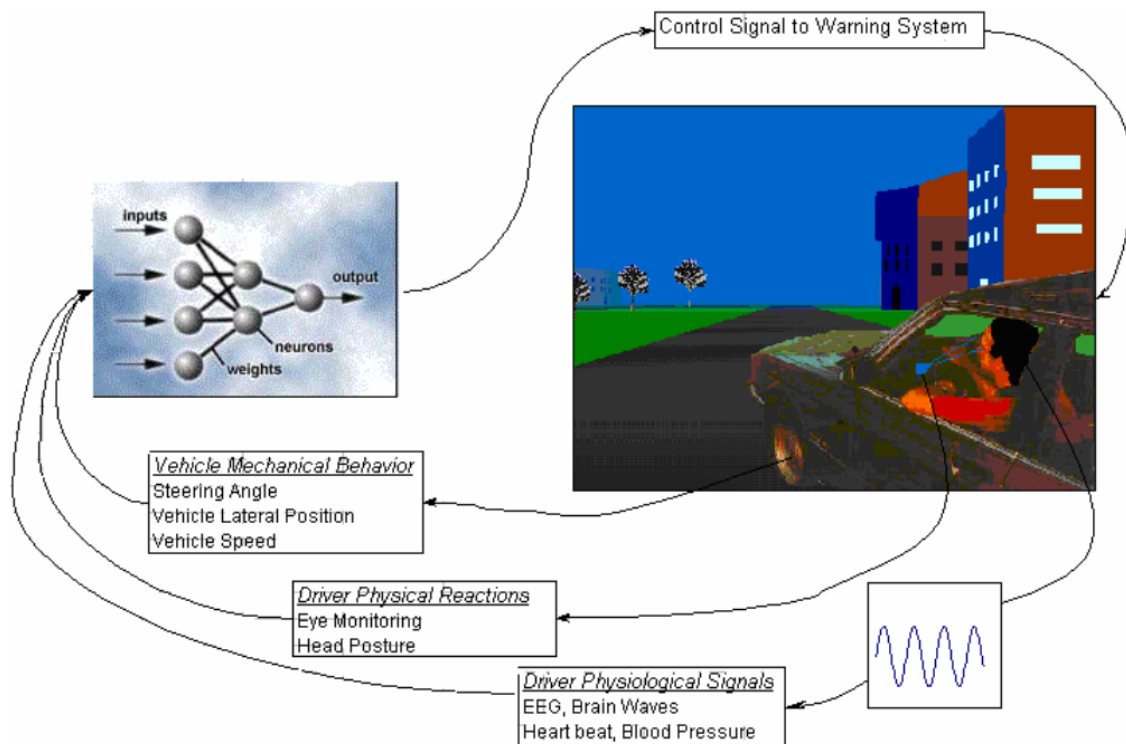


Ilustración 1. Sistema de detección de conductores somnolientos usando redes neuronales artificiales.

Varias tecnologías se han introducido en los últimos años para detectar los robos de automóviles, por ejemplo, Inmovilizadores para desactivar de forma remota los vehículos desaparecidos,

Electrónica de Identificación del Vehículo (IVE) para identificar el vehículo teniendo en cuenta una base de datos de registro, Sistema LoJack para el uso de transmisores incorporados para la localización de vehículos, GPS para localizar la posición de los vehículos perdidos utilizando el sistema de posicionamiento global, entre otros Guo [37]. Existen pocos trabajos desarrollados en los cuales se implementen técnicas de inteligencia computacional para el análisis de señales del vehículo en sistemas de seguridad antirrobo. Los trabajos más relacionados utilizan redes neuronales para el reconocimiento de patrones en sistemas de seguridad a través de la identificación del rostro del conductor, entre los cuales están los desarrollados por Liu [38, 39].

2.5.2 Control Clásico

Guldner [9] concentra su análisis en vehículos autónomos, más exactamente, en el desarrollo de dos controladores automáticos para la dirección del auto, basados en técnicas de control robusto no lineal. Su trabajo presenta con rigurosidad la discretización de los algoritmos de control propuestos.

Un estudio de la dinámica del sistema de tracción de un automóvil híbrido es objeto de investigación para WALTERMANN [40]. La interacción entre la dinámica lateral y la frontal dan lugar al diseño de un controlador a ser implementado en el vehículo híbrido. Este controlador se basa en el modelo de la máquina de combustión interna, el modelo para el motor eléctrico DC, el modelo de las baterías y el modelo dinámico del vehículo.

Son variadas las desventajas que presentan las técnicas de control clásico, como el PID, ante su contraparte basada en técnicas de Inteligencia artificial. Un contraste entre ambas técnicas es el que presenta HONGYAN [41] en el diseño de un controlador capaz de optimizar el consumo de combustible para un sistema de transmisión adaptativo, en donde el comportamiento del modelo es no lineal y el manejo de gran cantidad de variables dependientes en el tiempo le dan la ventaja al control moderno.

2.6 VALIDACIÓN

2.6.1 Simuladores

Los simuladores para diagnóstico de conducción errónea mediante sistemas inteligentes, comprenden una investigación en varias áreas: sistemas de diagnóstico inteligente para el

vehículo, análisis de los comportamientos de conducción errónea y el diagnóstico inteligente basado en redes neuronales.

En cuanto a los sistemas de diagnóstico para el vehículo, Schwall [42] ha propuesto un sistema de diagnóstico para uso en automóviles desarrollado en hardware. En su trabajo se muestra la importancia que tiene el uso de simuladores, introduciendo fallas en un sensor de velocidad, en la reducción de los costos de hardware ya que aplican análisis de redundancia por software. Además de que no requiere de sensores adicionales, su sistema de diagnóstico permite una alta precisión y bajos costos de desarrollo mediante el uso de la información desde múltiples modelos. Ellos logran esto mediante simulación basada en una red bayesiana para el procesamiento del modelo y para determinar el comportamiento temporal de las fallas y su probabilidad.

En cuanto al análisis de los comportamientos de conducción errónea, CHEN [43] ha logrado obtener un modelo de conductor y un modelo para la incertidumbre del mismo a partir de datos obtenidos de un simulador de conducción. Ellos usan la incertidumbre estructurada para representar las variaciones en el tiempo de los comportamientos que realizaría un conductor. Esta incertidumbre estructurada es una estimación y adaptación para el diseño de controladores para sistemas de seguridad activa.

Así mismo, muchos estudios proponen métodos de inferencia probabilística aplicados a la modelización y el reconocimiento de los comportamientos de un conductor. KUMAGAI [15], infiere una distribución probabilística del tiempo de inicio de frenado por una red bayesiana estática de varios elementos, tales como condiciones climáticas, métodos de conducción, resultados de estilo, entre otros. FORBES [44], proporcionó un modelo para la toma de decisiones de un vehículo autónomo en un entorno de simulación simple. OLIVER [14] utilizó un modelo oculto de Markov para el modelado y el reconocimiento de las maniobras de conducción a un nivel táctico. PENTLAND [45], aplica un filtro de Kalman de conmutación para el modelado y el reconocimiento de los comportamientos de conducción simulados.

Finalmente, en cuanto a los simuladores de conducción que se presentan en el mercado, a continuación se presenta una lista de aquellos que pueden ser utilizados en una eventual

implementación de esta investigación por sus características de adquisición de datos, análisis de telemetría, software libre, capacidad de integración con otros programas y los modelos físicos implementados:

- Simax.
- Racer.
- Live for Speed.
- Vamos. Automotive Simulator.
- Type S.

2.6.2 Plataformas reales

Resulta interesante conocer las evaluaciones a las que son sometidas muchas de las aproximaciones teóricas, ya sea en laboratorio o en campo. Fei Wang [21] desarrolló un sistema embebido en FPGA para detectar la apertura/cierre del párpado. Su trabajo muestra desde la etapa de diseño de la algoritmia hasta las implementación hardware en un núcleo NIOS® de ALTERA.

Un trabajo similar lo realizó Moreno[46], complementándolo con la detección de las líneas de demarcación de la carretera. Lo más interesante es la comparación de rendimiento entre dos núcleos de procesamiento: un DSP TMS320C6711® de la Texas Instruments y una FPGA 10K30RC208-4 de Altera®. Aunque el DSP realiza las mismas acciones en mucho menos tiempo (0,2ms vs. 12,65ms), siempre queda abierta la discusión sobre costos de producción ante una eventual replicación comercial del planteamiento.

El método propuesto por McCall [47] consta de una implementación que combina el comportamiento del conductor, haciendo uso de cámaras en pedales y cabeza; el entorno del vehículo, mediante cámaras externas y radares de proximidad; y la información del vehículo, mediante la lectura de la ECU usando un Data Logger del protocolo CAN; con el fin de medir la intención de desaceleración del conductor y desarrollar un sistema de asistencia en el frenado. Estas pruebas son llevadas a cabo sobre vehículos dotados de toda la sensórica requerida para constituirse como plataformas de investigación, como el vehículo inteligente LISA-Q [48]o el UYANIK [49].

BLOECHER [24] expone el esquema de implementación de un sistema de múltiples sensores de radar en un Mercedes Benz Clase E y su interacción con los sistemas que ofrecen asistencia de frenado, control de cruce adaptativo, identificación de punto ciego y asistencia para conservar el carril.

Un prototipo del sistema propuesto por SCHWALL [42], fue implementado y probado en un Mercedes-Benz Sedán E320. Una patente relacionada con dispositivos hardware para el diagnóstico dentro del auto fue desarrollada por LEMELSON [3], la cual es un dispositivo para el monitoreo del rendimiento de la conducción. Las aceleraciones instantáneas y la posición del vehículo son continuamente sensadas y guardadas en la memoria de un computador para obtener las variables de rendimiento. Estas variables son analizadas a través de un sistema inteligente neuro-difuso para evaluar cómo está siendo conducido el vehículo. Cuando patrones de conducción erróneos y peligrosos son detectados, se generan señales para advertir al conductor y/o a las autoridades.

2.7 TENDENCIAS

Aunque todos los adelantos tecnológicos en la línea de transportes inteligentes apuntan hacia el desarrollo de dispositivos y sistemas que ofrezcan mayor seguridad en las vías, tanto para conductores y pasajeros, como para los peatones; se debe evaluar la incidencia en los usuarios finales de estas nuevas propuestas. Por ejemplo, según estadísticas del 2007, sistemas de asistencia vehicular como el ABS registraron una reducción en el número total de accidentes y en el número de accidentes con heridos, pero al mismo tiempo registraron un aumento del 6% en las estadísticas de accidentes fatales. Este fenómeno contraproducente a un método de asistencia vehicular tan popularizado, se asocia con una excesiva confianza para algunos conductores; mientras que para otros, se asocia con un desconocimiento de las manifestaciones propias que este tipo de sistemas ejecutan ante un eventual acción correctiva en un evento de peligro[25].

Es cierto que todos los sistemas comerciales con los que en la actualidad (2011) cuentan los vehículos se basan en la mitigación de los daños físicos que se sufren durante el accidente, pero no previenen la ocurrencia del accidente mismo. Y es que el compromiso se encuentra entre el costo de implementación y la potencia de cómputo requerida. Valayden [50] propone y valida un

sistema experto que, basado en sensórica de bajo costo, cumple con los requerimientos de tiempo real que exige el tratamiento de señales infrarrojas empleadas como medio de detección del entorno del vehículo.

Chan [51] se centra en la detección de cambios en el comportamiento de una persona que realiza tareas repetitivas, y basa su desarrollo en un modelo de conductor que se acerca a un cruce vehicular. Sin embargo, el objetivo inicial de presentar un sistema de monitoreo no se logra debido a la incapacidad de diagnosticar un comportamiento impropio en distintas clases de conductores, al basarse en simple medición de sensores de velocidad, distancia con el cruce y los tres pedales. El autor concluye afirmando la necesidad de usar un sistema que monitoree la evolución del comportamiento del conductor, fundamentándose en aprendizaje no supervisado para poder diagnosticar la condición de manejo erróneo.

Uno de los trabajos más interesantes en cuanto a recolección de datos es el que expone ABUT en [49]. En su trabajo se encuentran involucradas varias instituciones académicas y de investigación, en busca de recolectar un completo dataset sobre un vehículo dotado con micrófonos, cámaras, sistemas de adquisición (Data Logger para Bus CAN) y computadoras de soporte. Se logra recolectar información sobre más de 50 conductores que realizan un recorrido pre-establecido de 25 Km en Estambul.

Varios son los estudios y la tecnología que se ha desarrollado para contribuir a la disminución de accidentes de tránsito y establecer las causantes de éstos una vez hayan ocurrido. De hecho, ya se cuenta con prototipos funcionales en el mercado en algunos países, no siendo una condición obligatoria el tenerlo instalado en cada vehículo, por lo que la “caja negra” para automóviles se ha convertido en una alternativa para mantener cierto control sobre los vehículos. Entre los diseños conceptuales propuestos por algunos autores se encuentra el desarrollado por Chae [52], donde presentan cómo recoger y gestionar eficazmente la información obtenida de las cajas negra para automóviles a través de redes vehiculares teniendo en cuenta la seguridad pública de dicha información. Este sistema graba imágenes de vídeo, sonido ambiente e interno, posición GPS, velocidad y tiempo. Estos datos pueden ser utilizados para la investigación precisa en accidente de tráfico y prevención de algunos delitos de carácter público.

Finalmente, hay que decir que todo sistema electrónico de asistencia al conductor debe considerar no sólo la sensórica del vehículo y aquella dedicada a captar las condiciones de su entorno, sino que también debe atender el componente humano[47]. De no hacerlo, se corre el peligro de que el sistema opere en contra de las intenciones del conductor, causando distracción o respuestas reflejas indeseadas. Esto puede llevar a la generación de falsas alarmas que, en el peor de los casos, restarán credibilidad al sistema de asistencia electrónico.

2.8 DISCUSIÓN SOBRE LA REVISIÓN

Según los estudios analizados, no existe un método completo para el diagnóstico de conducción cuya información dependa netamente de la información disponible en la computadora del vehículo - ECU. Los métodos propuestos, en su mayoría, dependen de información que entregan cámaras y sensores de radar, métodos de sensado que implican un sobrecosto y un trabajo de instalación adicional para su funcionamiento en vehículos convencionales. El Modelo planteado para esta Tesis propone la extracción de información de la ECU a través de protocolo CAN mediante un CAN Data Logger. Además, aunque algunos de los métodos propuestos determinan umbrales que permiten establecer características intrínsecas de cada conductor en miras de su identificación, y algunos otros discriminan entre los diversos tipos de alteraciones de conciencia a los que obedecen tales comportamientos, no correlacionan los resultados en miras de obtener un esquema genérico para conducción bajo condiciones normales. Este enfoque será abordado por el Modelo de Diagnóstico propuesto, con el fin de establecer un patrón adaptativo de conducción bajo condiciones normales, que actualizará sus parámetros acorde con las características intrínsecas de cada conductor.

Finalmente, se destaca una falta de integración entre los distintos mecanismos de sensado, los modelos planteados para análisis de la dinámica del vehículo y los métodos para análisis del comportamiento del conductor. Cada una de las soluciones atiende a una problemática en particular. El Modelo planteado en esta Tesis ofrece una visión global que responda a las necesidades de los actores de la seguridad vial en miras de lograr una plataforma completa para vigilancia y regulación de las vías.

3 DESCRIPCIÓN GENERAL DE LA PROPUESTA

Desde 1996, la EPA (Environmental Protection Agency) propuso para todo vehículo un sistema de telemetría llamado OBD (On Board Diagnosis), el cual es un estándar que ofrece un diagnóstico del estado de la máquina en función de condiciones para la correcta emisión de gases. A través de este estándar, es posible adquirir las señales de los sensores del pedal del acelerador, pedal del freno, ángulo de giro del volante (para algunos modelos de vehículos) y la velocidad, entre otros. Un receptor del sistema de GPS (Global Positioning System) es el complemento ideal para geo-referenciar esta información. Para el desarrollo de esta investigación, el papel de este sistema de adquisición de datos es llevado a cabo a través del simulador de conducción *Racer*³ desarrollado por Ruud Van Gaal, el cual es una plataforma libre (para uso no comercial) que posee un motor de realidad virtual para la simulación de modelos físicos de autos profesionales. *Racer* garantiza un registro de múltiples variables que proporciona el modelo, incluyendo las contempladas por el sistema OBD, con una tasa de muestreo que puede alcanzar los 10ms.

Por ser necesaria la caracterización de modelos de conducción correctos y erróneos, los cuales son obtenidos a partir del diagnóstico de cinco señales (acelerador, freno, posición, timón y velocidad) que provienen de diferentes conductores, tipos de autos y carreteras; es conveniente que se presente una etapa de procesamiento previo al diagnóstico de conducción, usando técnicas que ofrezcan un procesado robusto y adaptivo, inmunidad al ruido y capacidad de aprender [53].

Una vez son tratadas las variables del sistema, que lo constituyen como una solución de sensado no intrusivo, es posible discriminar entre un manejo bajo condiciones normales o una conducción errónea. Dependiendo de cada condición, el sistema deberá ejecutar un objetivo principal, así:

1. Para el caso de conducción normal, debe aprender continuamente con el fin de afinar un patrón genérico, capaz de adaptarse a las condiciones impuestas por la población objetivo que sea calificada bajo este rango.
2. Para el caso de conducción errónea, debe poder discriminar entre las distintas alteraciones de conciencia que inducen estos comportamientos inadecuados.

³ Para más información del simulador, visitar: www.racer.nl

La posibilidad de llevar un registro de datos históricos permite llevar a cabo la identificación del conductor mediante técnicas de reconocimiento de patrones, teniendo en cuenta que cada conductor posee características propias de manejo que permiten discriminarlo dentro de la población analizada.

La implementación de un sistema de diagnóstico demanda retos tecnológicos en materia de sensado, transmisión, almacenamiento y procesamiento de información; que no se encuentran disponibles en vehículos comerciales y que son la principal motivación para plantear esta Tesis.

El diagrama de Bloques mostrado en la Ilustración 2, plantea la Arquitectura del Sistema Funcional propuesto. A continuación se describirán cada uno de los bloques, explicando la pertinencia de su inclusión dentro de la solución planteada.

3.1 DIAGRAMA DE BLOQUES

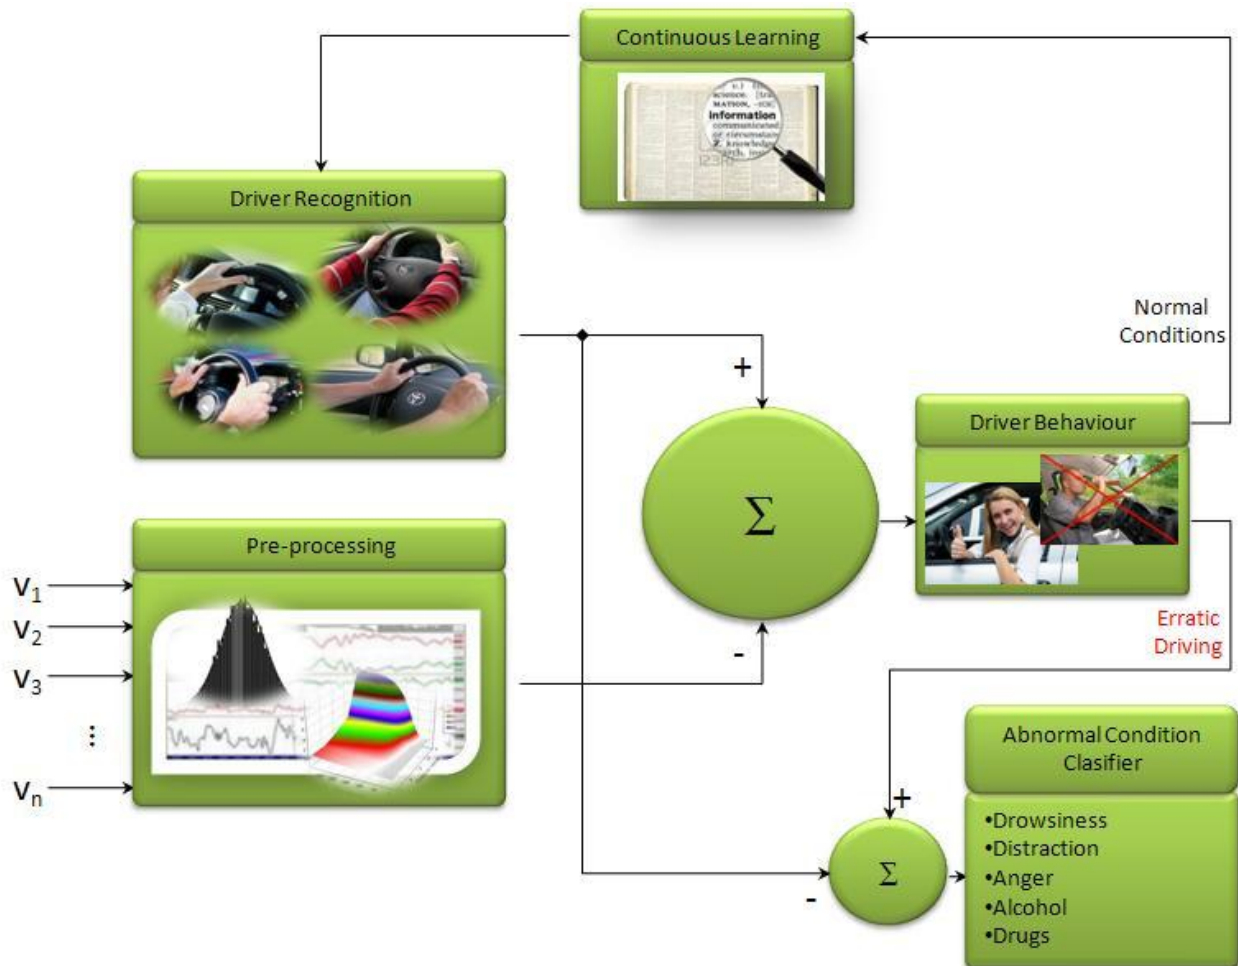


Ilustración 2. Arquitectura del Sistema Funcional propuesto

3.1.1 Pre-procesamiento (Pre-processing)

Las entradas de este bloque deben ser variables que aporten al sistema de información del conductor, del vehículo y su entorno. Como se ha visto en la Sección 2.4, son variados los métodos de sensado usados con el fin de extraer información relevante para lograr múltiples propósitos. No obstante, esta Tesis propone el uso de variables disponibles por la computadora del vehículo (ECU), con el fin de no agregar sensórica externa adicional a un simple módulo GPS. El método no contempla el empleo de cámaras.

Bajo esta premisa, se supone entonces que el vehículo cuenta con la información suficiente para poder armar un modelo que permita diagnosticar si una persona conduce bajo condiciones normales o si lo hace bajo alguna alteración. Ello implica la inminente necesidad de dar tratamiento a algunas de las variables provistas por la ECU, afianzando una etapa de extracción de características, según el esquema de clasificación que propone Duda[54].

Así, se ha supuesto que las variables seleccionadas deben proveer información en alguno de los siguientes formatos:

- Variaciones de su amplitud en el dominio del tiempo
- Variaciones de su amplitud en el dominio de la frecuencia
- Alteraciones marcadas en alguno de sus parámetros estadísticos, estudiados bajo una ventana de tiempo.

Como plataforma para posteriores análisis, se debe geo-referenciar el conjunto de variables asociando su valor instantáneo con una correspondiente trama de coordenadas geográficas provistas por un módulo GPS.

Se aclara que el modelo propuesto supone una velocidad de extracción de los datos, tal que su almacenamiento y pre-procesamiento cumplan con los requerimientos de respuesta que demanda una siguiente etapa que determinará el comportamiento del conductor.

3.1.2 Determinación del comportamiento del conductor (Driver Behavior)

Una vez las variables han sido extraídas de la ECU y, aquellas que lo ameriten, han sido pre-procesadas; se consolidan como entrada para un bloque decisor. Este bloque es capaz de evaluar características, conjuntos de características o funciones de estos conjuntos; como resultado del análisis que ejecuta un sistema experto basado en técnicas de Inteligencia Artificial.

Este sistema considera 5 *aspectos específicos* en el desempeño del conductor:

- Mantenerse en el carril correspondiente.
- No salirse de la carretera.
- No exceder los límites de velocidad.

- No ejecutar acciones bruscas en el manejo del timón.
- No hacer un mal uso de la combinación de pedales durante el recorrido de análisis.

El sistema experto será capaz entonces de clasificar al conductor como aquel que conduce normalmente o como aquel que lo hace bajo condiciones anormales, fundamentado en un análisis de las variables previamente procesadas en una ventana de tiempo. Esta última clasificación depende de la determinación de una regla o un conjunto de umbrales que permitan la discriminación propuesta.

3.1.3 Aprendizaje Continuo (Continuous Learning)

Según las condiciones expuestas en la sección introductoria de este Capítulo, éste bloque debe ser entrenado inicialmente con un conjunto de características asociadas a los cinco *aspectos específicos* mencionados previamente, siempre que se haga bajo un patrón de manejo normal. Toda alteración o conjunto de alteraciones debe ser estudiada para determinar cuál de ellas conlleva a un diagnóstico de manejo erróneo.

Dado el caso en el que el sistema clasifique al conductor bajo *condiciones normales*, un nuevo sistema capaz de analizar cómo se comportan las variables bajo este estado, actualiza el conjunto de características que definen el patrón de *condiciones normales*. Este patrón se encuentra definido para toda la población bajo estudio y no sólo para el individuo evaluado en particular. Es importante aclarar que los parámetros a actualizar no tienen que ver con el sistema de diagnóstico del bloque anterior, esto es, lo que se altera es la caracterización de lo que es considerado una conducción normal basada en los cinco aspectos antes mencionados. De esta forma el sistema hace adaptativo el proceso de diagnóstico de conducción errática a nivel de registro general y no individual.

3.1.4 Reconocimiento del Conductor (Driver Recognition)

El Sistema en estudio cuenta con una base de datos que alberga las principales características de conducción para cada conductor. Es así como se puede establecer cuáles variaciones, y sobre qué *aspectos específicos*, son las que caracterizan a cada conductor. De esta manera es posible identificar a cada conductor, siempre que se cuente con un número de muestras significativas para su análisis.

La salida de este bloque constituye la base de comparación para otros dos bloques permitiendo: la determinación del comportamiento del conductor o la discriminación del tipo de condición anormal de manejo, dado un diagnóstico de manejo erróneo.

3.1.5 Clasificador de Condiciones Anormales de Manejo (Abnormal Condition Classifier)

Una vez se dictamina el manejo erróneo, el sistema es capaz de reconocer si el conductor se encuentra bajo alguna de las condiciones anormales de manejo definidas, también llamadas alteraciones de conciencia. Este trabajo propone que este proceso de clasificación se fundamente en el análisis de las variaciones en *aspectos específicos* del manejo de cada conductor.

Un amplio espacio de estas alteraciones de conciencia comprende conducir bajo efectos de:

- Sueño
- Distracción
- Ira
- Alcohol
- Alucinógenos

Para el presente trabajo se han validado sólo las dos primeras alteraciones de conciencia, por restricciones en el espacio muestral. No obstante, los resultados reflejan que un análisis similar permitirá caracterizar las tres alteraciones de conciencia faltantes, robusteciendo aún más el clasificador.

3.2 DIAGRAMA DE FLUJO

La Ilustración 3 muestra el flujo-grama a seguir por la solución planteada para la presente Investigación. Al comienzo se inicializa un contador que será el encargado de discriminar entre una simple alerta y un diagnóstico de manejo erróneo, siempre que las condiciones de manejo normal se vean alteradas.

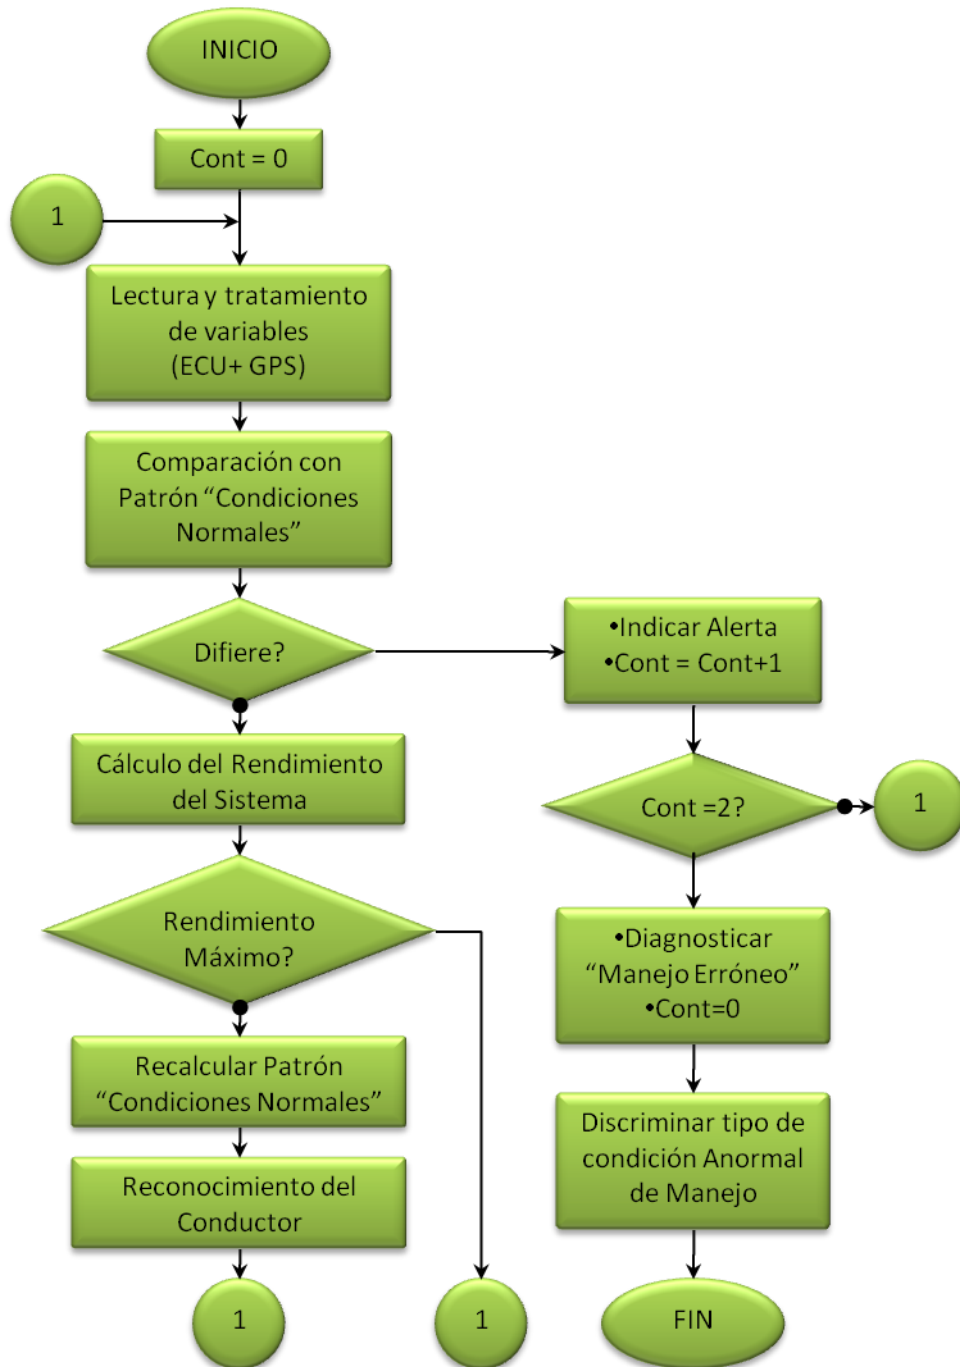


Ilustración 3. Diagrama de flujo del planteamiento propuesto

Posteriormente, se procede a dar lectura geo-referenciada de las variables entregadas por la computadora del vehículo (ECU) para su comparación con un patrón de manejo ideal, conocido como de “Condiciones Normales”. Dicho patrón se encuentra pre-establecido y es el resultado de un entrenamiento previo. No obstante, el sistema tiene la capacidad de re-entrenarse, según lo descrito en la Sección 3.1.3. Tal como plantea el Diagrama de Bloques de la Ilustración 2, es en este punto donde se decide si hay un manejo normal o un manejo erróneo.

Para el caso de manejo normal, el sistema se dedicará a aprender en busca de establecer y perfeccionar el patrón generalizado de manejo óptimo para todos los conductores inscritos en la base de datos. Sin embargo, este aprendizaje no está siempre presente pues se supone que habrá un umbral para el cual no vale la pena seguir aprendiendo. Es una curva de rendimiento máximo la que establecerá si se continúa o no en el proceso de actualización del modelo de manejo ideal.

Una vez se atiende la etapa de aprendizaje, el sistema procederá a identificar al conductor obedeciendo a un algoritmo de reconocimiento de patrones capaz de discriminar el modo de manejo según el análisis de los *aspectos específicos*.

Para el caso de manejo erróneo, el sistema lanza una primera alarma que alertará sobre un posible estado de conducción bajo condiciones anormales. En dicha evaluación, se vuelve a repetir el proceso de comparación de las variables tomadas del vehículo actualizadas con el patrón ideal. En este punto, si se continúa bajo un manejo indebido, el sistema diagnosticará una condición de Manejo Erróneo.

Finalmente, el sistema será capaz de discriminar entre las condiciones anormales de manejo descritas en la Sección 3.1.5.

4 DESCRIPCIÓN DE LA HERRAMIENTA DE SIMULACIÓN - EDDSystem

Para efectos de validar el modelo propuesto, ha sido requerido el uso de un simulador de diagnóstico de manejo erróneo, desarrollado en la Universidad del Norte: EDDSystem [55]. Este simulador extrae información de una consola de timón y pedales conectada a un computador para recorrer las pistas que se ofrecen en el simulador *Racer*, brindando un buen acercamiento al modelo propuesto. Se aclara que *Racer* es usado como plataforma para generación de una experiencia de manejo basada en realidad virtual, y como plataforma de registro de variables del modelo del vehículo.

El EDDSystem es una herramienta software que permite al usuario evaluar la manera en que conduce un vehículo en un entorno simulado, y cuya descripción funcional será descrita a lo largo de la Sección 4 a modo ilustrativo.

4.1 VARIABLES DE ENTRADA

Para el diagnóstico del comportamiento del conductor, el EDDSystem se hace uso de las siguientes variables:

- Posición del vehículo
- Ángulo de giro del timón
- Presión del pedal acelerador
- Presión del pedal freno

Los automóviles modernos tienen integrados varias características destinadas a brindar soporte para seguridad y facilidad de localización. Dos de las tecnologías actuales más utilizadas para estos fines son los sistemas GPS y OBD II, que brindan información acerca del estado del vehículo y su posición, entre otros datos.

Estas señales han sido obtenidas a partir de un entorno de simulación, que a partir de una interfaz de usuario permite conducir un automóvil, según se verá en la Sección 4.2. Durante cada recorrido de prueba realizado, el motor del emulador hará una lectura constante del estado del

acelerador, freno, volante, velocidad y posición del automóvil, mostrando una respuesta a los cambios de estas señales en el entorno virtual.

Esta información se constituye como una perfecta alternativa para simular las variables de entrada que sirven como insumo para el bloque de Pre-Procesamiento descrito en la Sección 3.1.1.

4.2 SIMULADOR DE REALIDAD VIRTUAL - RACER

Racer es una plataforma de simulación libre (uso no comercial), para la conducción de automóviles. Este simulador usa modelos físicos profesionales para los vehículos y las carreteras, y posee un excelente motor de realismo gráfico, de tal forma que ofrece una sensación realista al momento de conducir. OpenGL es usado para la renderización. El programa y el código fuente de *Racer* tienen derechos reservados de Ruud van Gaal, Dolphinty, 2000 – 2001. En la Ilustración 4 se pueden observar algunas imágenes del simulador.



Ilustración 4. Racer: plataforma de simulación para la conducción de automóviles.

Este simulador fue seleccionado para recolectar los recorridos de validación del modelo propuesto por esta Tesis, según los siguientes criterios:

- ❖ Ofrece interconectividad con consolas de timón y pedales convencionales, estableciendo una interfaz simple y real con el conductor.

- ❖ Posee una herramienta para la integración de *Racer* y Matlab, la cual permite convertir los archivos .log en formato ASCII que genera *Racer*, tras los análisis telemétricos de un recorrido, a archivos .mat compatibles con Matlab. Para el funcionamiento de esta herramienta (log2mat.exe) de manera automática, estableciendo una interfaz de análisis de cada movimiento del conductor por Matlab, es necesario la construcción de un programa que ejecute el archivo ejecutable en mención.
- ❖ El archivo de análisis telemétrico generado por *Racer*, permite la adquisición de las señales que requieren para la ejecución del sistema inteligente de diagnóstico: el ángulo de giro del volante en grados (positivo cuando gira a la izquierda); acelerador y freno, normalizadas de 0 a 1; la posición x, y, z en metros; y las velocidades vx, vy y vz, en m/s.
- ❖ Posee un archivo de inicialización de parámetros antes de ejecutarse (Racer.ini) por medio del cual se pueden modificar algunos parámetros de la simulación a través de Matlab, como la selección del vehículo y de la carretera, el tipo de cámara, el tamaño de la pantalla y el volumen. En la Ilustración 5, se muestran algunas características de la interfaz gráfica desarrollada para la interacción del simulador con Matlab.
- ❖ Los modelos físicos implementados por *Racer* poseen seis grados de libertad para el movimiento del chasis de los vehículos y suspensión independiente para cada rueda. Adicionando la posibilidad de modificar los entornos, hacen que *Racer* permita al usuario sentirse de forma parecida a una conducción real.
- ❖ Este software es gratuito, y es desarrollado con fines investigativos. No obstante, no es código abierto (Open Source).
- ❖ *Racer* ofrece la posibilidad de escoger el recorrido entre tres carreteras distintas: BADLANDS, CARLSWOOD y THE RIVER.



Ilustración 5. Interacción de Matlab con el simulador.

4.3 DIAGRAMA GENERAL

La herramienta adecuada para el análisis de señales provenientes de un automóvil debe poder ofrecer un procesamiento robusto y adaptivo, debe poseer la capacidad de aproximar y clasificar, además debe ser inmune frente al ruido. Además, se quiere que el sistema pueda utilizar sus experiencias pasadas para hacerse a sí mismo un sistema más efectivo. Las redes neuronales artificiales ofrecen las características anteriormente mencionadas, y han sido implementadas como técnica de procesamiento para la herramienta de simulación EDDSystem.

Por todo lo anterior, y para la etapa de detección, EDDSystem usa redes neuronales cuyas entradas son las señales GPS u OBD. El fin de las redes de detección es dar una calificación, entre 0 y 1, para dar a entender la magnitud de la falla realizada. El sistema inteligente de

detección es capaz de aprender la importancia de cada falla realizada en un set de pruebas para entrenamiento.

Luego de haber conseguido calificar el número e importancia de las fallas cometidas por el conductor, el sistema entrega una calificación generalizada para todo el recorrido, con el fin de dar a entender en qué medida se condujo de forma incorrecta. Para esto el EDDSystem cuenta con una red neuronal de salida, cuyas entradas son los valores máximos y promedios de las fallas cometidas. La Ilustración 6 exhibe un esquema general del sistema, mostrando que se parte de las señales obtenidas de un volante, el acelerador y el freno de un vehículo, y se utiliza la información de la carretera y la posición del vehículo. Sin embargo, se aclara que el sistema también tiene en cuenta la normativa de tránsito para excesos de velocidad en la carretera.

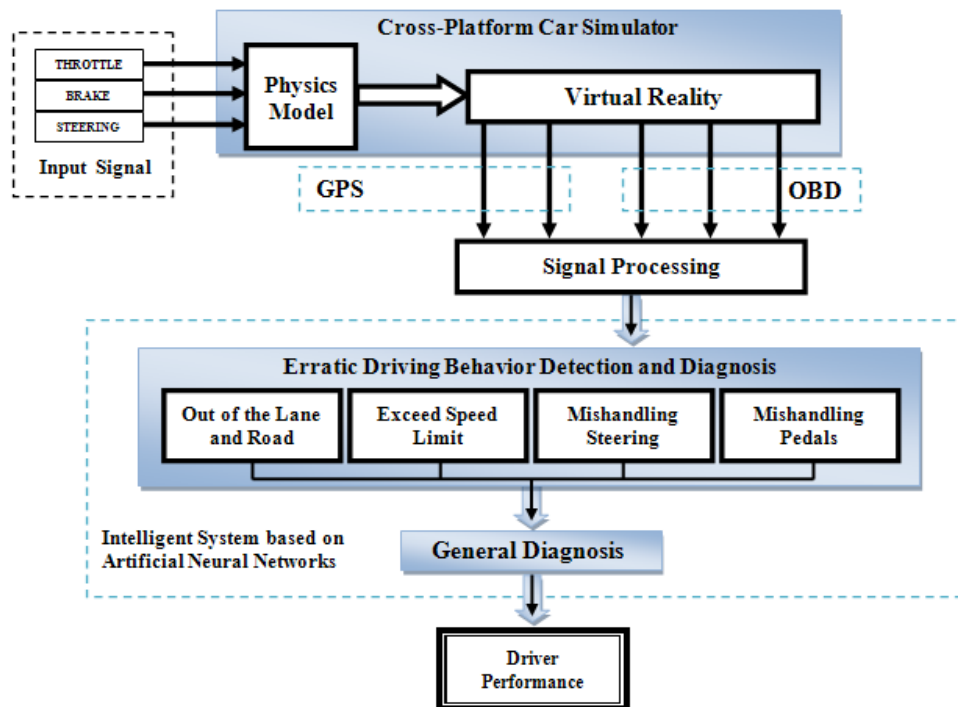


Ilustración 6. Diagrama general del sistema de diagnóstico.

En total, el EDDSystem cuenta con cinco (5) redes neuronales cuyas estructuras se asemejan, debido a la forma de su funcionamiento. Es decir, a partir de las entradas se ha escogido en valor entre 0 y 1 a modo de calificación de desempeño. Por otro lado, el EDDSystem usa un

entrenamiento supervisado con datos extraídos de recorridos de conducción simulados, hecho que no permite extender los entrenamientos a un número provechosamente alto. Con todo esto, se puede permitir aplicar el mismo tipo de red y entrenamiento a todos los sub-sistemas, cada uno con ciertas diferencias topológicas. Adicionalmente, se ha desarrollado un algoritmo complementario que ha permitido evaluar distintas alternativas y calcular el mejor desempeño para cada una de las cinco redes, estableciendo específicamente: el número de neuronas, el número de capas necesarias y las funciones de transferencia de cada capa.

4.4 SISTEMA DE DIAGNÓSTICO

Los diseñadores del EDDSystem conciben este sistema como el encargado de emitir un diagnóstico basado en una calificación cuantitativa sobre el error en la conducción. Obedece a una valoración ponderada sobre los diagnósticos individuales de cada *aspecto específico*. Altas valoraciones corresponden entonces a conducción errónea. Su salida es primordial para determinar si el bloque de “Aprendizaje Continuo” (3.1.3) debe seguir actualizándose o si el sistema debe dedicarse a discriminar el tipo de condición anormal de manejo (3.1.5) bajo la que se encuentra el conductor, según lo planteado por el flujograma del Modelo en 3.2.

Desde su concepción, el EDDSystem permite que el usuario pueda manipular diferentes parámetros para la ejecución del simulador, como lo son: condiciones de visibilidad y audio, datos personales del usuario, tipo de auto y carretera (ver Ilustración 7). Durante el recorrido, la manera de conducir del usuario es evaluada teniendo en cuenta los siguientes comportamientos erróneos: salirse del carril, salirse de la carretera, sobrepasar límites de velocidad y cometer movimientos bruscos con el timón o con los pedales. Al finalizar el recorrido, éste es reproducido nuevamente ejecutándose la detección y el diagnóstico cuantitativo de las anteriores señales, mostrando en la interfaz la posición del vehículo, velocidad, kilometraje y tiempo de recorrido. Tanto en la Ilustración 8 como en la Ilustración 9 se muestra la Interfaz Gráfica de Usuario para el EDDSystem.

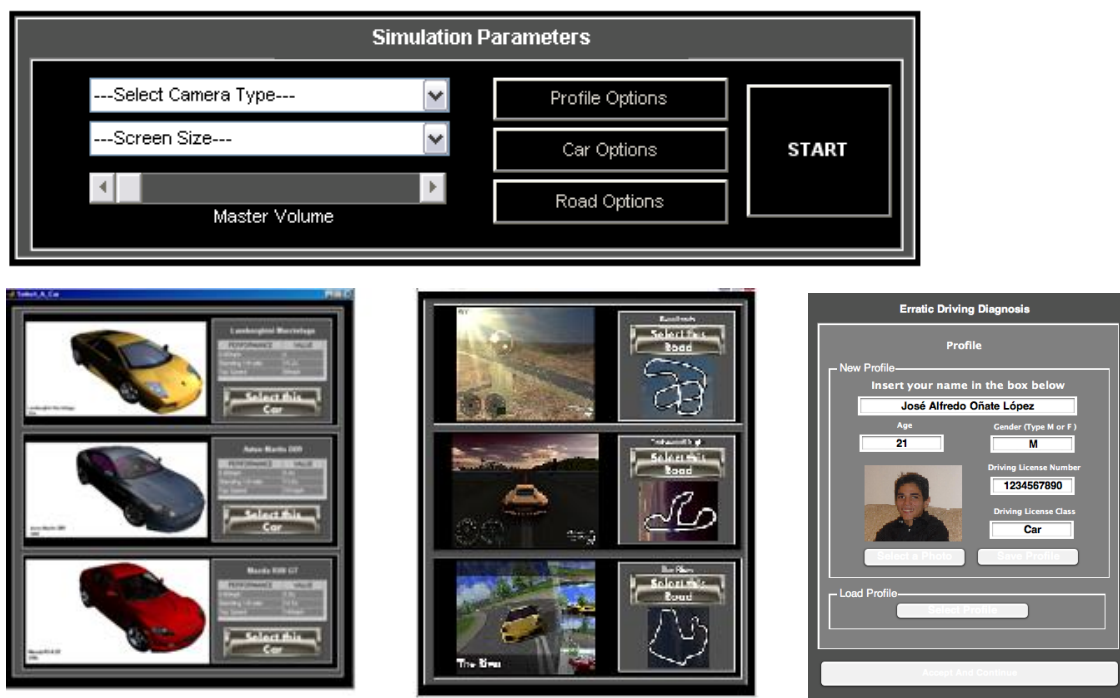


Ilustración 7. Parámetros para ejecución del Simulador de Conducción.

Posteriormente, es ejecutado un diagnóstico final que evalúa todo el recorrido realizado por el usuario presentándole un porcentaje de cuán errado ha sido su desempeño como conductor. Además, muestra las posiciones de la carretera en donde cometió cada uno de los comportamientos erróneos otorgándoles la respectiva calificación cuantitativa.

La salida de cada una de las redes neuronales que componen el EDDSystem, se constituye como información para determinar un conjunto de características descriptoras de cada conductor, de su forma de aprendizaje, de su comportamiento ante eventuales alteraciones de conciencia y, finalmente, de las zonas de riesgo de una carretera, con un meta-análisis estadístico.

A continuación se describen cada uno de los subsistemas que permiten la detección de maniobras de conducción errónea.

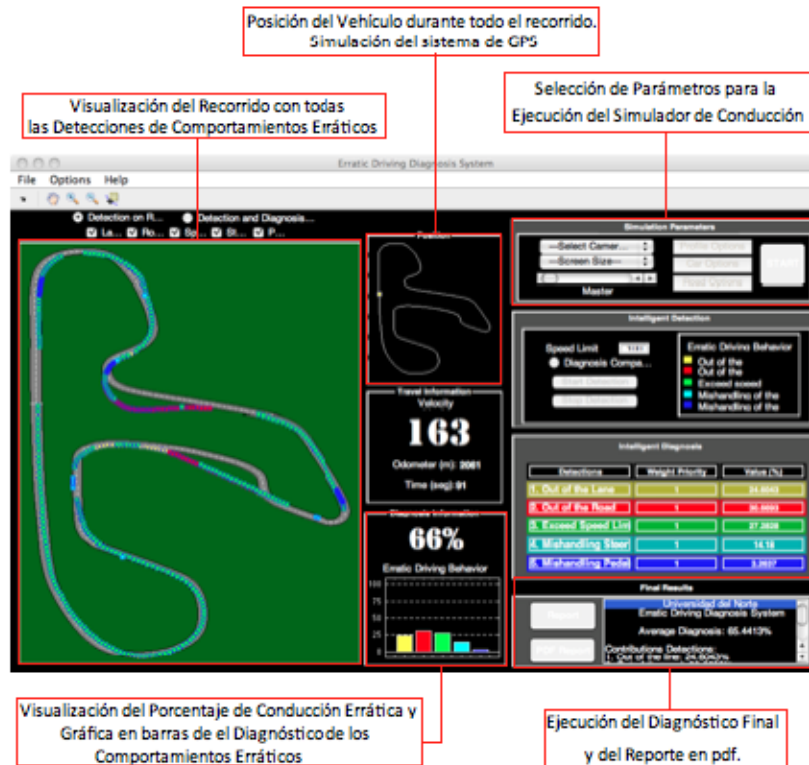


Ilustración 8. Diagnóstico del EDDSystem.

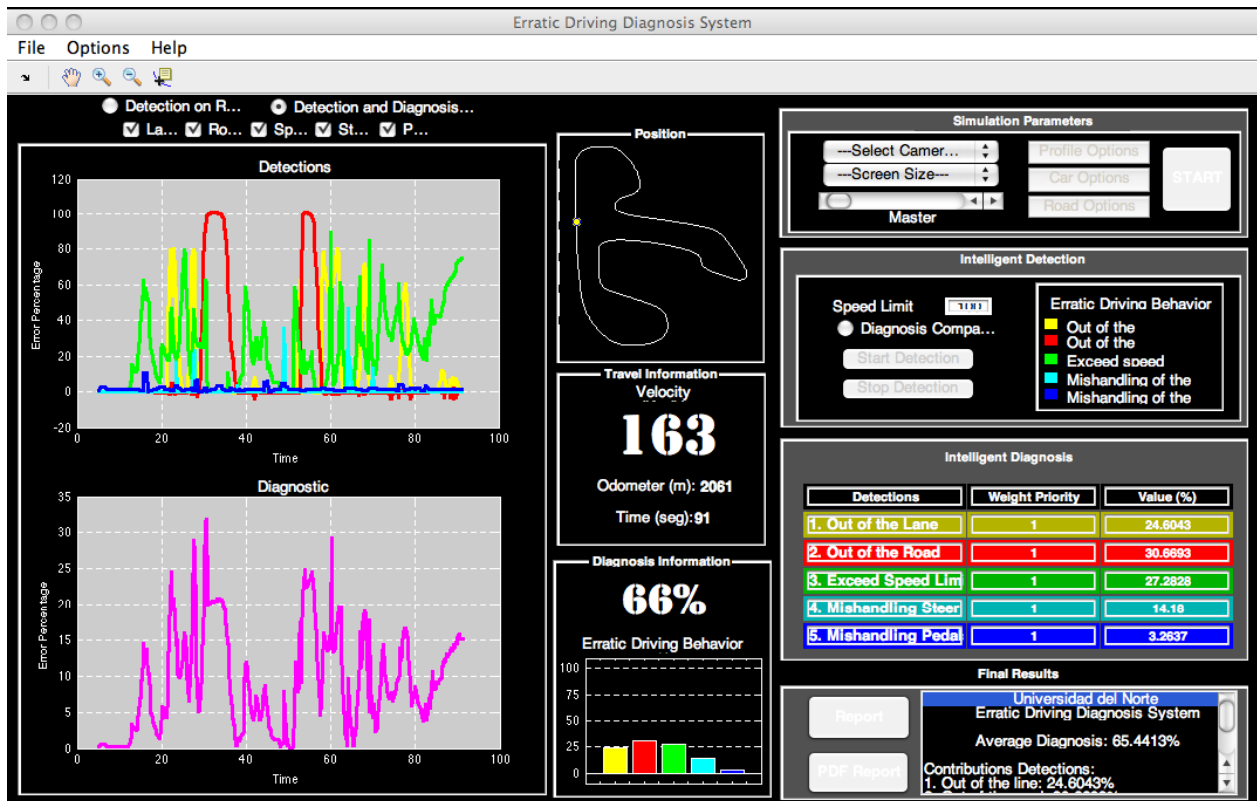


Ilustración 9. Análisis de Aspectos Específicos del EDDSystem.

4.4.1 Subsistema para Diagnóstico de Posición

Contando con los grandes avances que ha tenido el desarrollo de sistemas de Rastreo Vehicular Automatizado, ya sea a través de sistemas GPS o cualquier otro Sistema Global de Navegación por Satélite, se justifica la posibilidad de adquirir información geo-referenciada a partir de la computadora del vehículo. Además, gracias a los levantamientos cartográficos para la construcción de mapas digitales, se puede tener información acerca de la ruta o vía por la cual está transitando el vehículo. El EDDSystem cuenta con la posibilidad de evaluar cuantitativamente errores asociados al abandono del carril o de la carretera, de manera independiente.

Desde una proyección a largo plazo, el desarrollo de esta investigación no sólo se visiona para su implementación en el interior del vehículo sino también se pretende que el sistema inteligente interactúe en una Central de Monitoreo que le rinda información sobre las características de las carreteras.




Ilustración 10. Cálculo de los datos de entrada para la red de posición.

4.4.2 Subsistema para Diagnóstico de Excesos de Velocidad

En cada país existe una normativa de tránsito que determina un límite de velocidad, cuya escogencia obedece al tipo de carretera en la que se encuentra transitando el vehículo. Es decir, puede haber limitantes más estrictas para algunas calles o avenidas en el interior de una ciudad, que para una carretera intermunicipal o internacional. Los factores que hacen variar los límites de velocidad en el ámbito urbano pueden ser debido al emplazamiento de colegios, zonas industriales, hospitales, etc. Sin embargo, a pesar de que la normativa de tránsito en la mayoría de países trata de contemplar la mayor cantidad de factores, es muy poco probable que surja una

normativa lo suficientemente compleja como para tener en cuenta cada uno de los factores propios de cada carretera, como rugosidad del piso, curvatura, entre otros.

Si se tiene en cuenta la información que puede ser obtenida por un sistema autónomo, en el interior de un automóvil, se debe acotar el problema a una menor cantidad de variables. Es decir, sólo se debe utilizar datos que pueden ser obtenidos a través de un sistema de posicionamiento (como GPS o un sistema de visión artificial que determine la posición lateral del vehículo), e información de la normativa general vigente, como el exceso de velocidad para una determinada carretera. Además, contando con la información que pueda ser ofrecida por los actuales sistemas de cartografía digital, se asume que se conoce la curvatura de la carretera por donde transita el vehículo.

Debido a que en realidad no existen límites de velocidad asociados a la curvatura de una carretera en una normativa real, el EDDSystem cuenta con la posibilidad de asumir que se ha sobrepasado un límite simplemente a partir de las experiencias de distintos usuarios de diferentes automóviles en donde, a “juicio propio”, se haya decidido que la maniobrabilidad del automóvil disminuyó en mayor o menor medida. Con esto, el sistema evalúa en qué porcentaje de error de conducción se ha incurrido, debido a un exceso de velocidad. Esto, de manera intuitiva, se puede traducir en que a medida que la velocidad lineal del automóvil aumenta, la proporción de error aumentará consigo, más aún, si la curvatura de la carretera aumenta también.

4.4.3 Subsistema para Diagnóstico de Cambios Bruscos en el Volante

El EDDSystem cuenta con la posibilidad de detectar no sólo cambios bruscos repentinos sobre el volante (alta tasa de cambio), sino también movimientos continuos donde varíe rápidamente el ángulo del volante, como por ejemplo hacer zig-zag. Todo este tipo de comportamientos son característicos de conductores somnolientos y en algunos casos de conductores bajo los efectos del alcohol.

Teniendo en cuenta estas características, el EDDSystem propone la solución de dicho problema obteniendo la transformada de Fourier de la señal del ángulo de giro del volante desde un segundo antes hasta el momento actual. Con esto, se busca determinar no sólo en qué magnitud

están ocurriendo cambios bruscos sino también a qué frecuencia. De esta forma, la red detecta cambios bruscos en el volante al tener como entradas la frecuencia que posee la mayor potencia de la señal y dicha potencia. En la Ilustración 11, se muestra un ejemplo de la transformada de Fourier de la señal del ángulo de giro del volante en un segundo determinado y se muestra cuáles son las entradas a la red.




Ilustración 11. Transformada de Fourier de la señal del ángulo de giro del volante.

4.4.4 Subsistema para Diagnóstico de Cambios Bruscos en los Pedales

El objetivo de de esta red de detección es determinar altas tasas de cambio en cualquiera de los dos pedales: el acelerador o el freno. De esta forma la red posee dos entradas determinadas por la derivada de la señal del acelerador y el freno. Debido a que un conductor puede desacelerar o dejar de frenar rápidamente, sólo se detectan altas tasas de cambio positivas, ya que si el conductor frena rápidamente es porque se encuentra bajo una situación en la que ha perdido el control del vehículo, o si acelera rápidamente pueda ser propio de estar bajo los efectos del alcohol. Además, con la información de los pedales, es posible analizar también malos hábitos de conducción al detectar cuándo el usuario presiona los dos pedales al mismo tiempo.

4.4.5 Red de Diagnóstico General

Teniendo en cuenta lo anterior, el EDDSystem propone la definición de diagnóstico de conducción errónea como una función de las detecciones de los cinco comportamientos erróneos

anteriormente definidos y unos pesos para cada una de estas señales, tal como se muestra en la siguiente ecuación:

$$D(t) = f(EDBD(t), FW)$$

donde $EDBD(t)$ son los resultados de las detecciones de los comportamientos erróneos, los cuales varían en el tiempo, y FW es una función de pesos.

El diagnóstico del rendimiento del conductor se realiza mientras se ejecutan las cinco redes de detección, de tal forma que el usuario pueda ver cómo está conduciendo. En consecuencia, el diagnóstico final dependerá del porcentaje de error que está cometiendo el conductor en cada señal de entrada al sistema. En la interfaz gráfica desarrollada se permiten modificar los pesos de cada detección. La ecuación que se busca que sea inferida por la red de diagnóstico está determinada por una ponderación de cada entrada según su peso. Teniendo esto en cuenta, la red de diagnóstico posee 10 entradas: la salida de cada red de detección y su peso, y una salida que determina el diagnóstico de conducción errónea que está cometiendo el conductor en ese instante.

5 DISEÑO DE EXPERIMENTOS Y VALIDACIÓN DEL MODELO PROPUESTO

El entorno físico en el cual se llevaron a cabo los experimentos fue el laboratorio, bajo la plataforma de simulación *Racer*. Dicho ambiente proporciona las condiciones controladas necesarias, para poder realizar una manipulación completa de las variables independientes de cada experimento, tal y como lo permita el espacio muestral con que se cuenta. Las variables independientes corresponden a los múltiples factores bajo los que se ejecuta la prueba y que para efectos de esta investigación pueden considerarse las siguientes: Pistas, Vehículos, Recorridos, Estado de Conciencia.

El número total de experimentos (NTE) ejecutado para la validación del Clasificador siguió la técnica del Factorial completo, en el que se consideran todas las opciones disponibles para los niveles propuestos en las variables independientes, por lo tanto se aplica el siguiente cálculo:

$$NTE = r \prod_{i=1}^k n_i$$

donde: r = número de repeticiones; k = factores; n= niveles.

Más adelante se explicarán los factores considerados para cada experimento, las pruebas ejecutadas y los resultados obtenidos.

5.1 ESPECIFICACIONES DE DISEÑO

Contando con la plataforma de simulación EDDSystem para la validación del bloque de Pre-procesamiento, según lo descrito en la Sección 3.1.1, se puede planear un conjunto de experimentos para la validación de los siguientes bloques constituyentes del Modelo propuesto en el Capítulo 3.

Las muestras fueron obtenidas gracias a la cooperación de conductores jóvenes con poca o ninguna experiencia en conducción para evitar los efectos adicionales sobre los resultados debido a sus conocimientos previos sobre técnicas de manejo real. De esta manera se pudo contar con un espacio muestral de más de 500 recorridos suministrados por la Universidad del Norte, obtenidos mediante la interfaz misma del sistema de diagnóstico en cuestión y que se encuentran

distribuidos en 12 conductores distintos, 3 tipos de automóviles, 3 carreteras y 3 estados de conciencia (sueño, distracción y normal).

Para ello se planteó una estrategia bajo tres enfoques principales: conductor; alteraciones de conciencia (sueño y distracción) y mapa de riesgo de la carretera; de tal manera que se pudieron establecer umbrales de decisión para determinados patrones de comportamiento. Cada uno de estos enfoques se encuentra ligado al Modelo de Diagnóstico planteado, permitiendo una caracterización del conductor y de la carretera, desde la perspectiva del conductor mismo.

- Para el enfoque del conductor se analizó:
 - Evolución: Se tomaron muestras de la base de datos de recorridos para cada conductor, en las que se tuvo en cuenta el mismo vehículo y la misma carretera.
 - Adaptabilidad: Se tomaron muestras de la base de datos de recorridos para cada conductor, pero con diferente vehículo y diferente carretera.
 - Contraste: Se tomaron muestras de la base de datos de recorridos para diferentes conductores, bajo las mismas condiciones (mismo vehículo y misma carretera).
- Para el enfoque de las alteraciones de conciencia se analizó:
 - Sueño: Se tomaron muestras de la base de datos de recorridos para cada conductor, en las que se encontraban en estado de somnolencia considerando el mismo vehículo y la misma carretera.
 - Distracción: Se tomaron muestras de la base de datos de recorridos para cada conductor, en las que eran sometidos a distracciones pseudoaleatorias (hechas en partes específicas del recorrido previamente definidas) considerando el mismo vehículo y la misma carretera.
- Para el enfoque del mapa de riesgo se analizaron muestras de los recorridos sobre cada carretera usando un mismo vehículo con diferentes conductores.

Considerando que la validación del modelo planteado en esta investigación consistió en un diseño de experimentos que permitió llevar a cabo la caracterización deseada del sistema de diagnóstico en cuestión, se pueden diferenciar dos fases principales de análisis de experimentos: Planteamiento de hipótesis y Afinamiento de hipótesis. Así, se distribuyó el espacio muestral de

la siguiente manera: 70% para la primera fase y 30% para la segunda. La distribución se realizó teniendo en cuenta que durante la fase de planteamiento, se requirió la mayor cantidad de recorridos que permitieron formular la hipótesis; mientras que el resto de recorridos se reservaron para el afinamiento de la misma.

Cada experimento consistió en la selección de recorridos conforme a los enfoques mencionados anteriormente, para luego hacerles un estudio mediante el sistema de diagnóstico EDDSystem [55], y finalmente analizar los resultados y determinar patrones de comportamiento y caracterizarlos mediante la determinación de sus respectivos umbrales de decisión.

5.1.1 Problemática

Para dar lugar al proceso de validación del Modelo de Diagnóstico es necesario identificar una serie de características que permitan describir a cada conductor y a su respuesta ante cambios de las condiciones de manejo. Es así como se ha identificado que el proceso de aprendizaje ofrece información suficiente para caracterizar tanto al conductor como a la carretera misma, desde la vivencia del conductor.

El proceso de adquisición de conocimientos y entrenamiento humano puede caracterizarse mediante *curvas de aprendizaje*. Estas curvas corresponden a la relación entre el nivel de aprendizaje alcanzado y el costo de dicho alcance durante el proceso[56]. El costo de aprendizaje se mide en el tiempo, los ciclos o las repeticiones necesarias para que una persona alcance determinado nivel de experticia.

Las curvas estudiadas se basan en la premisa de que las personas hacen mejor los procesos a medida que éstos se repiten. Cuando el proceso en cuestión no muestra mejoras significativas o el desempeño se encuentra alrededor de un valor específico, se dice que hay saturación en el entrenamiento y al nivel alcanzado en este estado se le llama *nivel de estabilización*. De esta forma el término *evolución* se define como el proceso en el que una persona pasa de un estado a otro durante un proceso de aprendizaje.

Según lo descrito en la Sección 4.4, el EDDSystem considera 5 *aspectos específicos* en el desempeño del conductor:

- Mantenerse en el carril correspondiente.
- No salirse de la carretera.
- No exceder los límites de velocidad.
- No ejecutar acciones bruscas en el manejo del timón.
- No hacer un mal uso de la combinación de pedales durante el recorrido de análisis.

Tal como se definió en la Sección 4.4.5, al finalizar un recorrido en una pista el EDDSystem proporciona una calificación general equivalente al porcentaje de conducción errónea realizada por el conductor. De esta manera, el EDDSystem castiga un mal comportamiento asignando una calificación alta de error. De lo anterior, aplicando el concepto de curvas de aprendizaje en las calificaciones del EDDSystem, se espera que para los primeros recorridos de cada conductor, el Sistema de Diagnóstico proporcione resultados con altos niveles de conducción errónea. Y continuando el concepto para los recorridos finales, se espera que el conductor muestre una mejoría reflejada en una disminución en los porcentajes de conducción errónea detectada (ver la Ilustración 12). De esta forma para estudios en los cuales se evalúa el comportamiento de un sistema de diagnóstico de conducción bajo un simulador pueden considerarse dos estados de evaluación:

- En el primer estado se encontrarán los diagnósticos de conducción errónea desfavorables, que es cuando el conductor comienza a asimilar las condiciones impuestas por el simulador, tales como:
 - El tipo de pista a recorrer: Se familiariza con las condiciones visuales.
 - Vehículo a utilizar: Se familiariza con el timón y los pedales.
 - Restricciones impuestas según las leyes de tránsito: Se ajusta a la velocidad máxima permitida y el carril de la pista correspondiente.

Para efectos de esta investigación se le llamará *estado inicial*.

- El segundo estado corresponde a la etapa en la que el conductor ha asimilado las condiciones mencionadas y por tanto se esperan diagnósticos de conducción errónea

favorables y con valores cercanos a un nivel específico. Para efectos de esta investigación se le llamará *estado equilibrado*.




Ilustración 12. Diagnósticos ideales

De esta forma debe existir un momento de *transición* en la evolución, donde se pase de un estado a otro. Este momento (recorrido) se define como aquel en el cual el conductor ha dominado las condiciones impuestas por el simulador y su nivel o experticia en conducción se estabiliza. Así, para efectos de este estudio, un conductor “evoluciona” cuando pasa del *estado inicial* al *estado equilibrado*. El reto radica entonces en encontrar el recorrido o repetición en el que determinado conductor pasa de un estado de evaluación a otro. Este recorrido se llamará, *recorrido de transición*.

Los errores cometidos al iniciar el proceso son los esperados durante el aprendizaje. Sin embargo, resultados que muestran un aparente desarrollo precoz pueden deberse a errores de medición o factores de azar, por lo que para el análisis esos casos deberían ser aislados. Igual condición ocurre cuando se refleja un bajo desempeño una vez se cuenta con la experiencia en el simulador mediante la ejecución de varios recorridos. Este comportamiento de falsos positivos al inicio de la curva de aprendizaje y de falsos negativos al final de la misma curva puede relacionarse con el concepto de curvas ROC (por su sigla en inglés “Receiver Operating Characteristic”) [57]. La Curva ROC refleja en un gráfico la validez de una prueba frente a una decisión binaria, evaluando la relación de los Falsos Positivos frente a los Verdaderos Positivos

(llamado en algunos documentos como sensibilidad con respecto a especificidad). Este método presenta relevancia por la discriminación de los resultados obtenidos con respecto a los resultados esperados con el objetivo de diagnosticar de una manera más acertada.

Teniendo en cuenta que los diagnósticos de conducción errónea deben mostrar una tendencia a disminuir a medida que aumenta el número de recorridos, fue necesario hallar un método en el cual pudieran evaluarse todos los diagnósticos discriminando los recorridos “buenos” (aquellos con bajo porcentaje de conducción errónea en el diagnóstico), de los recorridos “erróneos” (aquellos con alto porcentaje de conducción errónea en el diagnóstico). Pero la particularidad de la evolución del conductor, hace que los primeros recorridos que se consideran “erróneos”, deban catalogarse como recorridos válidos, dado que son los resultados esperados en el *estado inicial*. Mientras que para el estado equilibrado los “buenos” recorridos, aquellos con baja calificación de manejo erróneo, son los recorridos válidos. Este comportamiento puede asociarse con el estudio considerado en las curvas ROC y de esta manera se pueden encontrar los falsos positivos (ocurridos antes del recorrido de transición) y los falsos negativos (ocurridos después del recorrido de transición).

Si se calcula el promedio de los diagnósticos del desempeño general del conductor, se observa que aquellos obtenidos a partir de los recorridos efectuados durante el *estado inicial* son los que más aportan al incremento del promedio, debido a que corresponden a aquellos con alto porcentaje de error; mientras que los obtenidos en el *estado equilibrado*, surten el efecto contrario.

Se pueden considerar como ejemplo los diagnósticos ideales mostrados en la Ilustración 12. Los diagnósticos de los primeros recorridos elevan el promedio general y los diagnósticos finales lo disminuyen. Esto ocurre debido a que ambos tipos de diagnósticos son válidos, pero sus aportes en el cálculo de un promedio general se anulan entre sí, porque los valores no reflejan la validez de sus datos y además se encuentran en extremos opuestos del comportamiento expuesto.

Para minimizar el efecto de falsos positivos y falsos negativos, se necesita transformar los resultados a un nuevo plano tal que todos los recorridos válidos (los “erróneos” durante el *estado*

inicial y los “buenos” durante el estado equilibrado) aporten al incremento en el promedio mencionado, en lugar de competir por estar en extremos opuestos de análisis y por tanto generar aparente anulación de sus efectos

Además del procedimiento anterior, se debe tener en cuenta que cada conductor presenta un promedio específico para cada estado. Debido a que las cualidades de manejo son propias para cada persona, cada conductor tiene su propio *nivel de estabilización*. Para establecer un patrón comparativo entre conductores, es necesario hacer una normalización de los diagnósticos considerando el mínimo y el máximo de sus calificaciones, que permita analizar si el conductor realmente ha evolucionado, sin importar qué tan bien lo ha hecho. La normalización aplicada se define como:

En la Ilustración 13, se muestran los diagnósticos de conducción de cada uno de los recorridos realizados por un conductor. En Ilustración 13 (b), se muestra el resultado de aplicarle la normalización a los recorridos mostrados en la Ilustración 13 (a). Se supone que con los diagnósticos de conducción normalizados puede calcularse ahora un *desempeño de evolución*. No obstante, si se define éste como el promedio de todos los recorridos normalizados, cuenta con el inconveniente del “ruido” que introducen en los cálculos los porcentajes de los recorridos no válidos de cada estado, al igual que sucede para el desempeño general.

En resumen, para una solución que permita un correcto análisis de los resultados históricos, se deben tener en cuenta:

1. Implementación de un nuevo plano de análisis, para minimizar el efecto de falsos positivos y falsos negativos.
2. La normalización de los datos, para comparar conductores entre sí.




Ilustración 13. Ejemplo de diagnóstico vs número de recorridos
a) Valores Reales b) Valores Normalizados

5.1.2 Solución: Método de Inversión

Como solución a la problemática anterior, se propone aplicar lo que para esta investigación se llamará el *método de inversión*, previa normalización de los resultados de diagnóstico.

Este método consiste en restas del tipo “1-Diagnóstico_Normalizado”, para invertir la valoración de algunos diagnósticos en el desempeño normalizado. Las restas se ejecutan desde un determinado recorrido en adelante. Así por ejemplo, si se quiere aplicar el método a partir del recorrido 12, todos los recorridos del 12 en adelante se reemplazan por su invertido: 1-Diagnóstico_Normalizado. Esta resta invierte los valores sin importar las diferencias en los diagnósticos de los diferentes individuos puesto que han sido previamente normalizados para que los valores de todos los conductores se encuentren en el mismo rango (0 a 1). En la Tabla 1 se observa la aplicación del método para el conjunto de diagnósticos normalizados de la Ilustración 13 (b). Los diagnósticos en rojo y cursiva son los invertidos de cada recorrido. Los recorridos válidos “buenos”, que reducían el valor del *desempeño de evolución*, ahora lo aumentarán (p.e. véase el diagnóstico del recorrido 19 de la Tabla 1 en las columnas 3 y 4) y así se elimina el inconveniente de la anulación de los diagnósticos en el cálculo de los desempeños.

Las restas del tipo “1-Diagnóstico_Normalizado” se practican a todos los recorridos inicializando a partir del diagnóstico 1, luego se practican desde el diagnóstico 2, y así sucesivamente hasta el último diagnóstico. El recorrido a partir del cual se aplica las restas se llama *recorrido de inversión*. Con esta información se crea una tabla con todos los *desempeños de evolución* para su análisis. Lo más relevante del método, es que se ha determinado que un simple análisis de la tabla

permite hallar el *recorrido de transición*, siendo este el correspondiente al *recorrido de inversión* cuyo *desempeño de evolución* exhibe un máximo local.

Recorrido	Diagnóstico Normalizado	Invertido desde 7	Invertido desde 12
1	1,000	1,000	1,000
2	0,612	0,612	0,612
3	0,029	0,029	0,029
4	0,769	0,769	0,769
5	0,344	0,344	0,344
6	0,679	0,679	0,679
7	0,270	<i>0,730</i>	0,270
8	0,444	<i>0,556</i>	0,444
9	0,597	<i>0,403</i>	0,597
10	0,429	<i>0,571</i>	0,429
11	0,584	<i>0,416</i>	0,584
12	0,579	<i>0,421</i>	<i>0,421</i>
13	0,000	<i>1,000</i>	<i>1,000</i>
14	0,190	<i>0,810</i>	<i>0,810</i>
15	0,077	<i>0,923</i>	<i>0,923</i>
16	0,137	<i>0,863</i>	<i>0,863</i>
17	0,011	<i>0,989</i>	<i>0,989</i>
18	0,142	<i>0,858</i>	<i>0,858</i>
19	0,165	<i>0,835</i>	<i>0,835</i>
20	0,063	<i>0,937</i>	<i>0,937</i>

Tabla 1. Ejemplo aplicación del método de inversión a partir de diferentes recorridos. Los recorridos invertidos se muestran en rojo y cursiva.

Con el fin de visualizar con más claridad el *método de inversión*, se plantearon un conjunto de diagnósticos de una serie de recorridos ideales, es decir, donde esté claramente definido el *recorrido de transición* (Ilustración 14a). Los literales b, c y d de la Ilustración 14 muestran los cambios en el conjunto de diagnósticos aplicando el *método de inversión* a partir de diferentes recorridos. Nótese que si se calcula el promedio general (desempeño de normalización) aplicando la *inversión* desde recorrido 11, que para este caso es el recorrido de *transición*, se obtiene el valor máximo, mientras que de allí en adelante aplicando la *inversión* desde recorridos posteriores, se observará que este promedio tiende a disminuir a medida que se aleja del recorrido de *transición*.

La Ilustración 15, presenta la variación del desempeño normalizado, calculado para cada *recorrido de inversión*, para el caso de recorridos ideales mostrado en Ilustración 14a. Nótese la tendencia del desempeño a disminuir a medida que el *método de inversión* se aplica para recorridos más alejados del recorrido de *transición*.

Se debe aclarar que los diagnósticos de los recorridos de *estado inicial* no necesariamente mostrarán un patrón definido. No se puede esperar que el retornar los diagnósticos a su valor original necesariamente implique un aumento en el nivel del desempeño de evolución como el observado antes del diagnóstico del recorrido 11 en la Ilustración 15. Los conductores en el *estado inicial*, pueden experimentar “suerte de principiantes”. Esto es, diagnósticos de conducción óptimos previos a su evolución real que, al analizar bajo el esquema de curvas ROC, se considerarían como falsos positivos. Es por esto que ese recorrido, en lugar de disminuir el desempeño explicado, lo aumentaría.

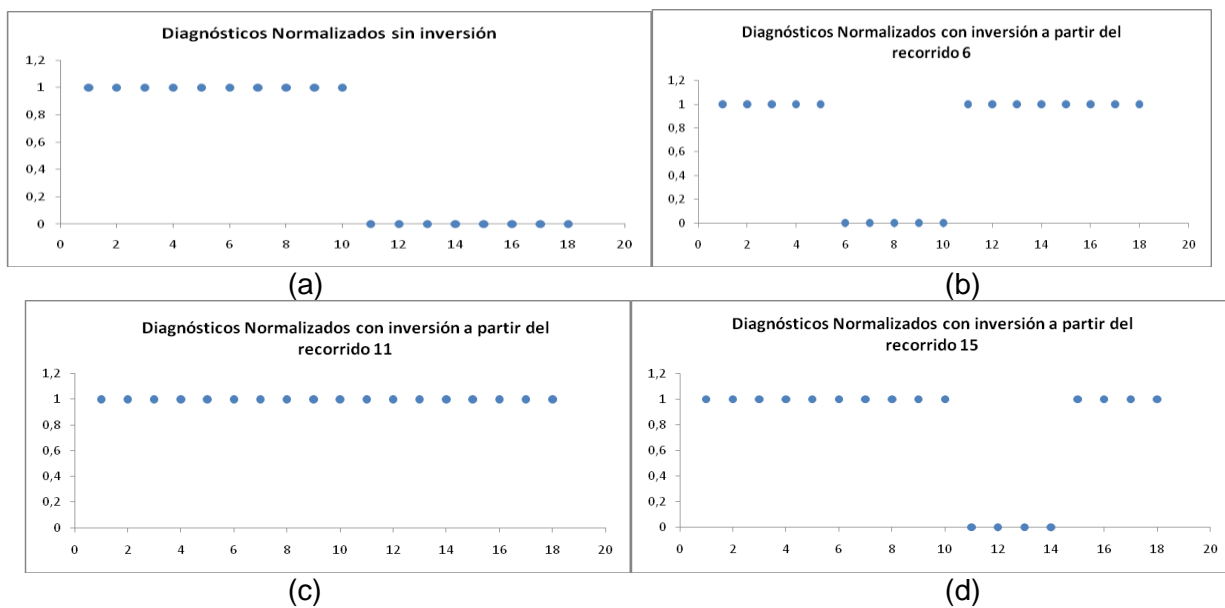


Ilustración 14. Método de inversión para diagnóstico ideal normalizado a partir de distintos recorridos.
a) Sin inversión. b) Aplicando la inversión antes del recorrido de transición. c) Aplicando la inversión a partir del recorrido de transición. d) Aplicando la inversión después del recorrido de transición.




Ilustración 15. Variación del desempeño normalizado.

Por otra parte, y tal como se mencionó previamente, en *estado equilibrado* existe el *nivel de estabilización*, al cual convergen los diagnósticos siguientes y, de haber mejoría en la conducción, los niveles de los diagnósticos de este estado son más bajos respecto al *estado inicial*. De lo anterior se infiere que, de existir estabilización, los diagnósticos de conducción convergerán a un nivel que será más bajo que los niveles de los diagnósticos de los primeros recorridos. Por lo anterior se puede entender la razón de la disminución en el *desempeño* de evolución cuando se usa un *recorrido de inversión* posterior al recorrido de *transición*, mientras se aplica el *método de inversión* explicado al inicio de este Capítulo.




Ilustración 16. Evolución de Desempeño Normalizado del caso real exhibido en la Ilustración 13.

La Ilustración 16 muestra el cálculo del desempeño normalizado realizado para cada uno de los *recorridos de inversión*, a partir del recorrido 2. Nótese que a partir del recorrido 13 se observa la disminución que ha de esperarse en caso de estabilización, la cual concuerda con la que visualmente se obtuvo, a partir de la Ilustración 13.

Aún cuando pareciese haber una tendencia a aumentar la curva de desempeño para el *método de inversión* durante los recorridos del *estado inicial* (acorde con lo observado en Ilustración 15), esta condición no se cumple necesariamente debido a que el comportamiento de cada conductor en esa etapa es diferente. La Ilustración 13b muestra que el conductor que realizó los recorridos experimentó “suerte de principiante”, en el *estado inicial* (para el recorrido 3), razón por la que en la Ilustración 16 no se observa la tendencia a aumentar el desempeño de manera sostenida.

5.2 EVOLUCIÓN DEL CONDUCTOR

Un estudio desde la perspectiva de la evolución que experimenta cada conductor permitirá establecer un patrón característico para cada individuo, a ser usado dentro de los bloques para “Determinación del comportamiento del conductor” (3.1.2) y “Reconocimiento del conductor” (3.1.4).

Considerando todo lo anterior, para esta evaluación se tomaron muestras de la base de datos de recorridos para cada conductor, en las que se tuvo en cuenta que estos los hubiesen practicado bajo el mismo vehículo y la misma carretera. A cada conjunto de diagnósticos de cada conductor se le aplicó el *método de inversión* y a cada conductor le fue hallado su recorrido de *transición*, en caso de tenerlo. El experimento debe contemplar que es posible que para algunos casos el conductor no muestre evolución en la cantidad de recorridos que realizó.

Los resultados fueron analizados con el fin de determinar el umbral del aprendizaje de conducción humano (una medida global dentro del espacio muestral) y los intervalos de confianza en los que se puede encontrar el nivel de *estabilización* de los conductores.

Para este experimento se utilizó la misma pista y el mismo vehículo de tal forma que se independizó el desempeño del conductor para su análisis. Como variables dependientes se

definieron: *Recorrido de transición* y *Nivel de estabilización* para el diagnóstico general. Como variable independiente se usó la cantidad de recorridos para los cuales se analizaría la evolución del conductor.

En esta fase se tomaron 16, 18 y 20 recorridos como opciones diferentes para el análisis, con el fin de comparar los resultados y observar posibles variaciones. Las pruebas se repitieron para 6 conductores: Oscar Sánchez, Estefanie Cure, Luis Severiche, María Severiche, Amiris Niño, Nataly Vilá. Como ejemplo se mostrará el análisis realizado para Luis Severiche en cada uno de los niveles definidos.

A modo ilustrativo, la calificación general entregada por el sistema de diagnóstico para cada uno de los recorridos de Luis Severiche se encuentra en la Tabla 2 y se pueden observar gráficamente en la Ilustración 17. A groso modo, de la gráfica se puede notar que los primeros 4 recorridos tienen un porcentaje de conducción errónea superior al resto, por lo que aparentemente se observa una notoria mejoría a partir del quinto recorrido.

Con 16 recorridos se observa el desempeño mostrado en la Ilustración 18. Al analizar este desempeño, se obtiene que el *recorrido de transición* corresponda con el número 5 (que resulta coherente con lo observado en la Ilustración 17). El *nivel de estabilización* corresponderá al promedio de todos los recorridos considerando a partir del *recorrido de transición* encontrado, por lo que para los valores mostrados en la Tabla 2, se obtiene un valor de 14,98 % de conducción errónea.

Recorrido	Diagnóstico Real	Recorrido	Diagnóstico Real	Recorrido	Diagnóstico Real
1	36,54	8	15,7	15	20,42
2	24,29	9	16,38	16	14,92
3	29,18	10	16,94	17	15,85
4	36,32	11	16,21	18	20,98
5	17,94	12	9,04	19	29,49
6	13,5	13	12,13	20	18,76
7	14,87	14	11,67	21	13,43

Tabla 2. Datos de Evolución de Conducción para Luis Severiche.




Ilustración 17. Gráfico de de Evolución de Conducción para Luis Severiche.




Ilustración 18. Evolución de Desempeño para Luis Severiche

Con 18 recorridos se realiza el mismo ejercicio anterior y se obtiene que el *recorrido de transición* es el número 5 (que sigue resultando coherente con lo observado en la Ilustración 17). El *nivel de estabilización* en este caso según los valores mostrados en la Tabla 2, corresponde a un valor de 15,47 % de conducción errónea. Con 20 recorridos se realiza el mismo ejercicio y se obtiene nuevamente como *recorrido de transición* el número 5 y en este caso el *nivel de estabilización* corresponde a un valor de 16,55 % de conducción errónea. Nótese que Luis Severiche presentó para cada uno de los experimentos el mismo *recorrido de transición*, por lo que se entiende que este conductor tiene bien definido el momento en que evoluciona. Sin embargo es necesario verificar sus *niveles de estabilización* para completar el análisis: Aumenta a medida que se toman más recorridos, no se mantiene ni disminuye, como se plantea en 5.1.1 cuando el conductor se encuentra en *estado equilibrado*.

Conductor	Nivel de Estabilización			Recorrido de Transición		
	Prueba1	Prueba2	Prueba3	Prueba1	Prueba2	Prueba3
Oscar Sánchez	10,54	10,26	11,47	8	8	8
Estefanie Cure	16,85	16,59	16,76	13	13	13
Luis Severiche	14,98	15,47	16,55	5	5	5
María Severiche	19,96	20,42	19,96	11	11	11
Amiris Niño	17,95	18,39	18,37	6	6	6
Nataly Vilá	17,77	17,28	17,52	4	4	4
Promedio Nivel	16,34	16,4	16,77			
Intervalo de confianza	3,62	4,02	3,18			

Tabla 3: Recorrido de Transición y Nivel de Estabilización de cada conductor en cada prueba.

Para hallar la explicación de este aumento se puede observar que en la Ilustración 17, Luis Severiche presentó recorridos con alto porcentaje de conducción errónea durante su *estado equilibrado*, entre los recorridos 18 y 20. Este tipo de recorridos son los que aumentan el *nivel de estabilización* del conductor si se tienen en cuenta para el cálculo del mismo y por eso se obtienen esos resultados. Este comportamiento de recorridos con alto porcentaje de conducción errónea durante el *estado equilibrado*, corresponde a los Falsos Negativos explicados en 5.1.1.

Con el mismo método aplicado a Luis Severiche se obtuvieron los *recorridos de transición* y *niveles de estabilización* para cada uno de los conductores restantes. La Tabla 3 registra los resultados obtenidos para cada uno de los experimentos (Prueba1=16, Prueba2=18 y Prueba3=20 recorridos).

En cada prueba se halló el promedio del nivel de estabilización y el intervalo de confianza necesario para cubrir el 83,3% de las muestras (correspondiente a 5 de 6 en este caso). Se observan valores similares en el promedio obtenido para las tres pruebas, y el intervalo de confianza mínimo para cubrir las muestras propuestas se presenta durante la última prueba (que comprende la mayor cantidad de recorridos analizados). Se observa también que el *recorrido de transición* para cada conductor no varió en las diferentes pruebas. Si el *recorrido de transición* presentara variaciones, los valores iniciales obtenidos corresponderían a máximos locales que se presentan en individuos con fases intermedias en el proceso de aprendizaje; es decir que serían recorridos de transición relativos, puesto que a ese proceso de aprendizaje le espera aún otra mejora posterior.

Para hallar la convergencia del *recorrido de transición*, se pueden diferenciar 2 objetivos importantes:

- Hallar la cantidad de recorridos necesarios para que el 83,3% (5 de 6) de los conductores logre pasar al *estado equilibrado*. Este análisis permitiría definir cuántas sesiones de manejo serían necesarias en un curso de conducción basado en el simulador *Racer*, para que una persona aprendiera. Según la Ilustración 19 esta condición se cumple a partir del recorrido 11.

- Hallar el recorrido con el intervalo de confianza mínimo para el que el 83,3% de los recorridos de transición de los conductores se encuentre en dicho rango. Según la Ilustración 20, esta situación ocurre por igual para los recorridos 7, 8 y 9 con los que se requiere un intervalo de confianza igual a 4 recorridos.




Ilustración 19. Conductores que han evolucionado según la cantidad de recorridos.




Ilustración 20. Intervalo de Confianza según el recorrido escogido como transición

La Tabla 4 muestra los resultados obtenidos para los experimentos (Prueba1=11, Prueba2=13 y Prueba3=15 recorridos). La convergencia del recorrido de *transición* es simple puesto que 2 de los 3 obtuvieron el mismo resultado, así que el valor convergería a 7. Se observa que los valores obtenidos en estos experimentos quedan contemplados dentro de los intervalos de confianza previamente mencionados para la validación de la *evolución del conductor*, y por tanto la hipótesis es congruente.

Conductor	Nivel de Estabilización			Recorrido de Transición		
	Prueba1	Prueba2	Prueba3	Prueba1	Prueba2	Prueba3
Carlos Rebolledo	13,47	13,59	12,62	9	9	9
David Brun	13,92	14,71	13,99	7	7	7
Roberto Armenta	13,80	13,14	12,56	7	7	7
Promedio Nivel	13,73	13,82	13,06			
Intervalo de confianza	0,19	0,67	0,50			

Tabla 4: Recorrido de Transición y Nivel de Estabilización de cada conductor en cada prueba

5.3 ADAPTABILIDAD DEL CONDUCTOR

Si bien es cierto que en el Modelo de Diagnóstico descrito en el Capítulo 3 no se menciona un estudio de adaptabilidad, y que este no afecta de ninguna manera los bloques bajo estudio, este se

destaca por ofrecer información relevante del conductor con un sencillo análisis de la información que ofrece el *Método de Inversión*.

Los conductores que han *evolucionado* gracias a su proceso de aprendizaje, han alcanzado cierto nivel de experticia en conducción. Estos conductores, bajo las mismas condiciones del simulador, no variarán sus cualidades de manejo ni sus diagnósticos diferirán significativamente del nivel de *estabilización*.

De acuerdo a la definición de los estados de *evolución*, en el *estado inicial*, un conductor mostrará diagnósticos de conducción errónea en la medida que no asimile las condiciones impuestas por el simulador. Seguidamente en el estado *equilibrado* los diagnósticos no serán de conducción errónea, puesto que ya ha asimilado tales condiciones. Se intuye que mientras se mantengan las mismas condiciones, el conductor no saldrá del estado *equilibrado*. Por consiguiente, en caso de que las condiciones impuestas por el simulador cambien, el conductor necesariamente tiene que pasar por un nuevo proceso de aprendizaje, asimilar las nuevas condiciones impuestas por el simulador y de esta forma volver a un *estado inicial* de evolución. Este proceso en el que el conductor tiene que acomodarse a estas nuevas condiciones y pasar nuevamente a través del proceso de *evolución*, pero bajo unas nuevas condiciones, es lo que para efectos de este estudio se denomina *adaptabilidad* del conductor. De esta forma un conductor se ha *adaptado* cuando nuevamente alcanza el estado *equilibrado* de evolución para las nuevas condiciones.

La *adaptabilidad* del conductor se debe medir según el número de recorridos que necesita un conductor, para alcanzar el estado *equilibrado* bajo las nuevas condiciones, teniendo en cuenta los que fueron necesarios para que *evolucionara* en primera instancia. Se analizan recorridos de un mismo conductor que ya ha evolucionado, bajo distinto vehículo y distinta carretera. En este estudio se comparan los recorridos de *transición* de cada proceso de evolución. Además, se ha establecido como umbral de *adaptabilidad* el número de recorridos requerido por cada conductor para *adaptarse*.

De manera similar al proceso que se llevó a cabo para los experimentos en 5.2, se ejecutaron las pruebas correspondientes a determinar la *adaptabilidad*, tendientes a encontrar el recorrido en el que se alcanzara el nivel de estabilización bajo las nuevas condiciones (nuevo vehículo y nueva pista). Debido a que la evolución de los conductores se ejecutó en la pista CARLSWOOD, para este experimento se ejecutó considerando los recorridos efectuados en THE RIVER posteriores al proceso de evolución, asegurando un automóvil diferente al usado durante el experimento de evolución. Los niveles considerados fueron de 8, 10 y 12 recorridos considerados para 4 conductores: Oscar Sánchez, Estefanie Cure, Amiris Niño, David Brun.

La Tabla 5 muestra los resultados obtenidos para cada uno de los experimentos. En cada prueba se halló el promedio del *nivel de estabilización* y el intervalo de confianza necesario para cubrir el 75% de las muestras (correspondiente a 3 de 4 conductores en este caso). El promedio del nivel obtenido disminuye a medida que aumentan las muestras, debido a que la cantidad de recorridos escogidos para este experimento en algunas pruebas no supera el recorrido de *adaptación* y por eso los conductores siguen mejorando.

Conductor	Nivel de Estabilización			Recorrido de Adaptación		
	Prueba1	Prueba2	Prueba3	Prueba1	Prueba2	Prueba3
Oscar Sanchez	21,37	14,23	14,05	6	9	9
Estefanie Cure	27,3	N.A.	11,33	6	N.A.	10
Amiris Niño	13,97	13,34	12,10	2	2	2
David Brun	18,85	18,59	18,13	6	6	6
Promedio Nivel	20,37	15,39	13,90			
Intervalo de confianza	6,40	2,04	2,57			

Tabla 5: Recorrido de Adaptación y Nivel de Estabilización en cada prueba de Adaptación.
(Prueba1=8 recorridos, Prueba2=10 recorridos y Prueba3=12 recorridos)

Por esa misma razón se puede observar el escenario presentado para Estefanie Cure, en el que: según la primera prueba su recorrido de adaptación era el 6, para la segunda prueba no se aprecia *estabilización* y para la última prueba se observa un nuevo valor para el recorrido de *adaptación*. El recorrido 6 para ese conductor se constituye precisamente en un máximo local durante el análisis de los datos mediante el *Método de Inversión*, debido a la fase intermedia en el proceso de aprendizaje detectada para este individuo. Es decir, que se le puede llamar *recorrido de*

adaptación relativo, puesto que al proceso de *adaptación* del conductor le espera aún otra mejora posterior. Estefanie Cure muestra esa mejora en la tercera prueba, donde se halla el recorrido definitivo en el que el conductor se adapta. Para los valores finales podemos considerar convergencia al sexto recorrido con un intervalo de confianza de ± 4 recorridos que en este caso cubre el 100% de las muestras.

La Tabla 6 muestra los resultados obtenidos para cada uno de los experimentos (Prueba1=8, Prueba2=9 y Prueba3=10 recorridos). En cada prueba se halló el promedio del *nivel de estabilización* y el intervalo de confianza necesario para cubrir el 100% de las muestras (pues sólo son 2 conductores en este caso). En el sexto recorrido ambos conductores se han adaptado, ajustándose al esquema esperado.

Conductor	Nivel de Estabilización			Recorrido de Adaptación		
	Prueba1	Prueba2	Prueba3	Prueba1	Prueba2	Prueba3
Carlos Rebolledo	7,65	7,06	7,35	3	3	3
Nataly Vilá	24,13	21,78	20,42	6	6	6
Promedio Nivel	15,89	14,42	13,88			
Intervalo de confianza	8,24	7,36	6,54			

Tabla 6: Recorrido de Adaptación y Nivel de Estabilización por conductor para Afinamiento.

5.4 CONTRASTE ENTRE CONDUCTORES

Como se mencionó en la etapa de *evolución*, cada conductor cuenta con cualidades propias de manejo. Dado que el EDDSystem permite realizar diagnósticos de *aspectos específicos* en la conducción, el contraste entre conductores radica en cuáles de estos *aspectos* diferencian un conductor de otro, según su desempeño individual. Este ejercicio resulta determinante para lograr el objetivo primario del bloque “Reconocimiento del Conductor” en 3.1.4.

De manera similar en la que sólo se tuvo en cuenta el diagnóstico general de conducción para determinar la *evolución del conductor* -Capítulo 5.2-, el *método de inversión* puede aplicarse sobre los diagnósticos de los *aspectos específicos*. El resultado permite determinar si un

conductor *evoluciona* o no en tales aspectos, lo que se constituye como el patrón comparativo entre conductores.

El hecho de evolucionar implica un cambio, es decir, que la persona modificó ese *aspecto específico* de manejo. Para efectos de este estudio, se le llamará *cualidad* propia del conductor a aquel *aspecto específico* en su conducción en el que no presentó *evolución*. La tarea del *contraste* entre conductores se enfoca a analizar, clasificar y comparar cada conductor de acuerdo a sus cualidades específicas de conducción. Al igual que la evolución de conductores se propone un método que para efectos de este estudio se llamará, *Método de Categorización de Conductores*, abreviado *MCC*.

El *MCC*, como su nombre lo indica, categoriza a cada conductor de acuerdo a sus cualidades de manejo. El método cuenta con un esquema de cuatro (4) pasos:

1. Extraer las *cualidades* de cada conductor: Mediante el *método de inversión*, se determina en qué *aspecto específico* el conductor evolucionó o no y así se determinan sus *cualidades*.
2. Definir *etiquetas de categorización* de acuerdo a las *cualidades* extraídas: Cada *cualidad* de conducción se relacionará con una *etiqueta de categorización* de acuerdo con el siguiente orden: Carril, pista, velocidad, timón y pedales.
3. *Clasificar* a los conductores de acuerdo a las *etiquetas*: Para este paso se diseñó una lista en la que se encuentran todas las combinaciones posibles de *cualidades* de conducción, que previamente se relacionaron como *etiquetas* y así definir *categorías* de conductor de acuerdo a estas combinaciones.
4. Comparar a los conductores de acuerdo a sus *categorías*: Con los conductores *categorizados*, se pueden realizar comparaciones entre quienes se encuentran en la misma *categoría*. El criterio de comparación entre estos radica en la diferencia del diagnóstico general y del estudio de superposición entre sus intervalos de confianza, que finalmente determina si los conductores son estadísticamente diferenciables.

	Carril	Pista	Velocidad	Timón	Pedales			Carril	Pista	Velocidad	Timón	Pedales
0	0	0	0	0	0		16	1	0	0	0	0
1	0	0	0	0	1		17	1	0	0	0	1
2	0	0	0	1	0		18	1	0	0	1	0
3	0	0	0	1	1		19	1	0	0	1	1
4	0	0	1	0	0		20	1	0	1	0	0
5	0	0	1	0	1		21	1	0	1	0	1
6	0	0	1	1	0		22	1	0	1	1	0
7	0	0	1	1	1		23	1	0	1	1	1
8	0	1	0	0	0		24	1	1	0	0	0
9	0	1	0	0	1		25	1	1	0	0	1
10	0	1	0	1	0		26	1	1	0	1	0
11	0	1	0	1	1		27	1	1	0	1	1
12	0	1	1	0	0		28	1	1	1	0	0
13	0	1	1	0	1		29	1	1	1	0	1
14	0	1	1	1	0		30	1	1	1	1	0
15	0	1	1	1	1		31	1	1	1	1	1

Tabla 7: Código de Categorías propuestas para el MCC.

En la Tabla 7 se especifican todos los tipos de conductores que se pueden definir mediante la categorización propuesta. Cabe anotar que por el hecho de que varios conductores se encuentren caracterizados por las mismas cualidades de conducción (misma categoría), no implica que presenten idéntica evolución sobre sus *aspectos específicos*. Un caso hipotético en el que dos conductores sean categoría 2, es decir que para ambos el manejo del timón sea una *cualidad* de conducción, no necesariamente implica que los dos tienen el mismo control sobre el volante. Quizás, puede que la característica principal de manejo del primer conductor sea su suavidad al volante, mientras que la del segundo sea su brusquedad al volante. Sus estilos de conducción son distintos, pero lo que caracteriza a ambos conductores es el hecho de que su dominio del timón no varía conforme aumenta su experiencia en pista.

La Tabla 8 muestra dos conductores hipotéticos con sus respectivas cualidades de conducción, según los *aspectos específicos* en los que no se presentó *evolución*. De ahí se entiende en este ejemplo que el conductor 1 no presentó evolución en los diagnósticos específicos de *pedales* y

velocidad, mientras que sí lo hizo para los aspectos de *timón*, *carril* y *pista*. Para el conductor 2, se determinó que no presentó evolución en los aspectos de *pedales* y *carril*, mientras que sí lo hizo para los aspectos de *timón*, *velocidad* y *pista*. Sin importar el nivel de experticia de los conductores en cuanto a su cualidad en los pedales, puede determinarse que una caracterización de manejo de ambos es la forma como controlan los pedales. Volviendo al ejemplo original, Conductor 1 puede ser brusco en los pedales, mientras que Conductor 2 sea más suave con los mismos.

CONDUCTOR	Conductor 1	Conductor 2
CUALIDAD		
Carril	0	1
Pista	0	0
Velocidad	1	0
Timón	0	0
Pedales	1	1
Categoría	5	17

Tabla 8: Ejemplo de contraste entre conductores.

En estos experimentos se desean comparar los desempeños de conducción de varios conductores bajo un mismo entorno de manejo. Para esto se categorizaron los conductores para luego compararlos. Se definieron como:

- Variables dependientes: los diagnósticos específicos de conducción
- Variables independientes: el número de conductores a contrastar (2, 4 y 6 conductores).

Conductor	Carril	Pista	Velocidad	Timón	Pedales	Categoría
Nataly Vilá	1	0	1	0	1	21
	37	N/A	22	N/A	9	
María Severiche	1	0	0	1	0	18
	34	N/A	N/A	16	N/A	
Estefanie Cure	1	0	0	0	1	17
	39	N/A	N/A	N/A	20	
Amiris Niño	1	0	1	1	0	22
	39	N/A	25	35	N/A	
Luis Severiche	0	0	0	1	0	2
	N/A	N/A	N/A	11	N/A	
Oscar Sánchez	0	1	1	1	1	15
	N/A	19	21	12	4	

Tabla 9: Categorías asignadas a los conductores luego de aplicar el MCC.

La Tabla 9 muestra las *categorías* de los conductores determinadas por el *MCC*. Al *categorizar* a cada conductor se observa que todos tuvieron clasificación diferente. Este resultado era de esperarse puesto que el número de *categorías* es 32, mientras que el número de conductores es 6; por esta razón las comparaciones se deben realizar a nivel de los *aspectos específicos*. El *MCC* puede mostrar resultados más discriminativos cuando se aplica a un número de conductores mayor que el número total de *categorías*.

Al tomar dos conductores (Nataly Vilá y María Severiche), se observa que comparten la *cualidad* de no salirse del carril y su desempeño es similar (37% para Nataly y 34% para María), por lo que en ese caso no es posible diferenciarlas. Las otras *cualidades* no son comunes por lo que, en cuanto a los demás diagnósticos, no pueden plantearse claras diferencias.

Al tomar cuatro conductores, se añade a Estefanie Cure y Amiris Niño. Las cuatro conductoras comparten tanto la *cualidad*, como el desempeño del aspecto específico carril pero no es posible diferenciarlas. Amiris comparte la *cualidad* de velocidad con Nataly pero también con similar desempeño, por lo que tampoco pueden diferenciarse en ese aspecto. Otra *cualidad* de Amiris es el dominio del timón que comparte con María, y lo hace con desempeño diferente (Amiris = 35%, mientras que María = 16%). Estefanie Cure cuenta además con la *cualidad* del pedaleo, la comparte con Nataly, con desempeños del 20% para Estefanie y 9% para Nataly.

Al tomar seis conductores se adiciona a Oscar Sánchez y Luis Severiche. La Tabla 9 muestra que Luis sólo tiene la *cualidad* de dominio del timón. La comparte con Oscar, Amiris y María. Pero se diferencia en el desempeño notablemente con Amiris. Con María y Oscar la diferencia no es notable. Oscar tiene todas las *cualidades* a excepción de no salirse del carril. Es el conductor con manejo más estable de todos los comparados. Su estilo de conducción puede caracterizarse por los desempeños de las *cualidades* que posee. Es el conductor que puede determinarse más fácil. Resumiendo, en la Tabla 10 podemos ver algunos de los contrastes analizados.

Por todo lo anterior, se puede hacer el siguiente enunciado: Para cuantificar una diferencia entre conductores se requiere que al menos posean una *cualidad* en común, y que su desempeño en

ella sea diferente. Se pudo notar que la diferencia promedio en el diagnóstico fue de 15%, así que se tomará dicho valor como el umbral de diferencia dentro de una *cualidad*.

Conductor 1	Conductor 2	Cualidad	Comentarios
Amiris Niño	María Severiche	Timón	Diferente desempeño
Nataly Vilá	Estefanie Cure	Pedal	Diferente desempeño
Amiris Niño	Luis Severiche	Timón	Diferente desempeño
Oscar Sánchez	N.A.	4 de 5	Fácil diferenciación

Tabla 10: Contraste entre conductores para el Planteamiento de la Hipótesis

5.5 ALTERACIONES DE CONCIENCIA (DISTRACCIÓN Y SUEÑO)

Los diagnósticos de *cualidades* específicas no sólo permiten establecer el patrón característico de *manejo bajo condiciones normales* para cada individuo, sino que también permiten encontrar la influencia de la alteración de los estados de conciencia en el desempeño de manejo de cada conductor. Este es el fundamento para llevar a cabo el objetivo de discriminación que plantea el bloque “Clasificador de Condiciones Anormales de Manejo” (3.1.5).

Para este objetivo se realizaron las pruebas a aquellos conductores que evolucionan en su conducción, tanto para el desempeño general como para el desempeño de las cualidades específicas. Esto con el fin de analizar conductores que lograron cierto nivel de experticia en el manejo y así eliminar cualquier influencia que “la no experticia” de los conductores no evolucionados puede tener en los resultados. Se determinaron en cuáles *aspectos específicos*, la distracción y el sueño influyen más en la evaluación para poder obtener las conclusiones al respecto.

Para determinar la influencia de los estados de conciencia en el desempeño de un conductor, se analizaron conductores que han evolucionado y, entre estos individuos, se compararon los *aspectos específicos* de un número de 1, 2 y 3 recorridos bajo alteraciones de conciencia, contra recorridos hechos por los mismos conductores, pero en estado normal.

En la Tabla 11 se observa la variación en los diagnósticos según el estado de alteración de conciencia. De acuerdo a los valores obtenidos, se observa que la distracción afecta todos los tipos de diagnósticos, pero en diferente intensidad. Las mayores diferencias se presentaron para carril y pedales. El aspecto pista desmejora un poco, mientras que para el aspecto de velocidad, no se observa cambio considerable. Al hacer el mismo análisis para los otros conductores se encontró que el carril es el aspecto en el que más se aprecia alteración del desempeño bajo distracción. Se puede inferir que el conductor deriva su concentración del manejo a un objeto de distracción, y en ese instante de tiempo no se alcanza a percatar de que el vehículo se desvía del carril correspondiente. Cuando percibe el error, puede ocurrir que se encuentre cercano a una curva y necesite mover los pedales bruscamente para hacer bien la maniobra de regresar al carril (esto puede explicar también el pedaleo de María).

ESTADO	Recorrido	Tipo de Diagnóstico					
		General	Carril	Pista	Velocidad	Timón	Pedales
Normal	1	18,21	0,00	17,72	54,77	23,46	0,02
	2	23,89	15,56	14,91	33,11	15,16	0,00
	3	14,57	19,72	22,13	0,00	17,04	0,00
Distracción	1	24,53	44,59	24,6	44,59	20,65	20,65
	2	32,84	42,55	22,3	42,55	26,08	26,08
	3	16,99	32,23	17,34	32,23	20,57	20,57
Sueño	1	49,87	98,49	98,34	0,00	14,78	12,75
	2	8,34	30,37	0,00	28,06	0,00	11,44
	3	48,23	100,00	100,00	19,45	0,00	12,93

Tabla 11. Diagnósticos obtenidos según alteración de conciencia para María Severiche.

Verificando los valores obtenidos para el caso de sueño se observa que los aspectos con mayor alteración son carril y pista, leve alteración del aspecto pedales, sin cambio observable en velocidad y, para sorpresa, se aprecia mejoramiento en el aspecto timón. Con valores tan altos de conducción errónea para pista y carril bajo efectos del sueño, se puede inferir que bajo esta alteración se puede perder totalmente la noción de la vía generando que el vehículo se salga del carril y/o la pista por la que viaja, su capacidad de reacción puede disminuir y por ello se puede justificar la disminución de porcentaje de conducción errónea para el aspecto específico de timón.

Los resultados anteriores permiten establecer que el *aspecto específico* carril es el discriminante entre los estados de conciencia estudiados, haciendo posible un diagnóstico certero sobre aquel bajo el cual se encuentra el conductor. Un conductor que presente altos porcentajes de diagnósticos de conducción errónea en ese aspecto específico, luego de un proceso de *evolución* (ya en *estado equilibrado*), puede considerarse que se encuentra bajo un estado de alteración de conciencia:

- Según los resultados obtenidos en la *evolución*, se observa que por lo general los conductores presentan diagnósticos superiores al 40% en el aspecto carril durante su etapa de iniciación, por lo que se define este valor como umbral límite para considerar en **estado distraído** a un conductor que ha evolucionado.
- En este experimento se observó que un conductor somnoliento obtiene valores superiores en el diagnóstico que los de uno distraído. Se definió el umbral en el 90% de conducción errónea en ambos aspectos (carril y pista) para determinar que el conductor se encuentra en **estado somnoliento**.

Es totalmente factible que la distracción sea la etapa que antecede el sueño, reforzando la anterior determinación de los umbrales de diagnóstico para estos estados de conciencia.

5.6 MAPA DE RIESGO DE LA CARRETERA

Al igual que para el estudio de *adaptabilidad*, el establecimiento de un Mapa de Riesgo no se encuentra contemplado dentro del Modelo de Diagnóstico descrito en el Capítulo 3. No obstante, durante el desarrollo de esta Tesis se plantea un novedoso Método que, basado en la geo-referenciación de la información que entrega el *Método de Inversión*, ofrece la posibilidad de establecer un esquema de zonas de riesgo para una carretera.

Con el fin de determinar las zonas más peligrosas de las carreteras, se ha diseñado un método para construir el mapa de riesgo. Cada pista se ha dividido en zonas delimitadas por puntos de control. Cada zona contempla la inclusión de tramos de pista en los que se espera que los conductores presenten una mayor tendencia de conducción errónea.

Luego, analizando los resultados de los recorridos realizados sobre el EDDSystem, se han estudiado aquellas zonas en las que el sistema de diagnóstico proporciona altos niveles de conducción errónea. Para cada zona se ha calculado el promedio de todos los diagnósticos, generales y específicos, con el fin de asignarle a dicha zona su peso de riesgo. La delimitación para construir el mapa de riesgo de las carreteras se muestra en la Ilustración 21. Las zonas de análisis para el *mapa de riesgo* de cada carretera se puede observar en la Ilustración 21 como el recorrido comprendido entre 2 puntos de control consecutivos; de esta forma se definieron 11 zonas para BADLANDS, 9 zonas para CARLSWOOD y 10 zonas para THE RIVER.




Ilustración 21: Puntos de control definidos para cada pista para construir su Mapa de Riesgo
a) Badlands. b) Carlswood. c) The River.

Para analizar el *mapa de riesgo* se organizaron las zonas de mayor a menor de acuerdo al porcentaje obtenido de conducción errónea, para cada uno de los experimentos de los conductores y para todos los conductores involucrados en la prueba. Esta organización ubica a cada zona en una posición exclusiva.

Realizando una sumatoria del número de veces que una zona queda en determinada posición, se obtiene una matriz con las posiciones obtenidas por todas las zonas a lo largo de los experimentos. Al colocarse un peso a las posiciones obtenidas, de tal forma que la posición 1 sea la de mayor peso e ir disminuyendo con el correr de las posiciones, puede hallarse una suma ponderada para cada zona, a partir de multiplicar el número de repeticiones de determinada zona por su peso ponderado. Para efectos de este estudio, este proceder se llamará *Método de Clasificación Ponderado*, abreviado MCP. Si se organizan nuevamente las zonas de mayor a menor de acuerdo al valor obtenido en la sumatoria del MCP, puede determinarse cuál es la zona más peligrosa. Los tipos de riesgos que ofrece una zona se pueden analizar, observando los diagnósticos específicos obtenidos en la zona en cuestión.

Se buscan identificar las condiciones de la carretera que incrementan el grado de dificultad para responder adecuadamente durante el manejo de la misma y que, por consiguiente, conllevan a errores de conducción cuando se circula por esos puntos. Se espera que en estas zonas el desempeño de conducción de los conductores desmejore debido a los cuidados adicionales que deberán tener para no perder el control del vehículo.

Como variables dependientes se tomaron los diagnósticos (tanto el general como los específicos) que proporciona el EDDS, para cada zona definida. Como variables independientes se definieron el número de recorridos a estudiar y las diferentes pistas. Los niveles en este experimento serán de 7, 9 y 11 recorridos. Los experimentos se repitieron para 5 conductores: Oscar Sánchez, Estefanie Cure, María Severiche, Luis Severiche y Amiris Niño. De acuerdo a lo planteado, se obtienen los resultados presentados en la Tabla 12, la Tabla 13 y la Tabla 14.

Este procedimiento permite hallar las zonas más riesgosas en cada pista. Para “Badlands” es la 4 y para “Carlswood” y “The River” es la 5. No obstante, este ejercicio no es suficiente para

definir qué tan peligrosa es. Es por ello que se ha tomado el umbral del 40% planteado, estableciendo que un conjunto de conductores conduciendo en estado normal llegarán al umbral establecido como de distracción sólo si la carretera ofrece un riesgo. Al encontrar algún diagnóstico que lo supere, se considera la zona como de alto riesgo de accidente.

En la Tabla 15 las zonas 7 y 5 de “Carlswood” superan el umbral del 40%. Esto coincide con los resultados que exhibe la Tabla 13, en donde estas zonas se clasifican en segundo y primer nivel de riesgo, respectivamente.

Zona	Posición alcanzada en orden de peligrosidad											MCP
	1	2	3	4	5	6	7	8	9	10	11	
1											12	12
2	6	1	2		1	2						113
3						2	4	6				56
4	1	7	1	3								114
5	2	1	3	2	1		3					97
6	2	1					3	4	2			69
7				4	5	3						85
8		1	4	1	4	2						94
9									2	10		26
10								2	8	2		36
11	1	1	2	2	1	3	2					90

Tabla 12: Cálculo de la sumatoria ponderada de las zonas de pista “Badlands” según MCP

Zona	Posición alcanzada en orden de peligrosidad									MCP
	1	2	3	4	5	6	7	8	9	
1						3	7	2		37
2				4	5				3	52
3		1	7	4						81
4						1	4	7		30
5	12									108
6			4	1	1	3	1	2		58
7		11	1							95
8				3	3	5		1		55
9					3				9	24

Tabla 13: Cálculo de la sumatoria ponderada de las zonas de pista “Carlswood” según MCP

Zona	Posición alcanzada en orden de peligrosidad										MCP
	1	2	3	4	5	6	7	8	9	10	
1							2	1	4	5	24
2			9	1		2					89
3				1	2	1	3	2	1	2	46
4				2	3	2	1	4			58
5	10	2									118
6							1	3	4	4	25
7				1	1	1	5	2	1		46
8				3	2	2			2	1	48
9		3		4	4	4					99
10	2	7	3								107

Tabla 14: Cálculo de la sumatoria ponderada de las zonas de pista “The River” según MCP

Recorrido	EDD por Zona								
	1	2	3	4	5	6	7	8	9
1	7,27	10,74	9,17	8,34	40,73	17,18	15,44	5,38	10,54
2	3,36	0,56	8,95	6,66	10,49	4,51	16,67	5,24	5,87
3	7,31	6,28	5,30	8,20	42,29	13,93	16,49	0,57	6,79
4	6,23	3,38	23,31	6,74	30,77	8,90	9,95	5,76	5,84
5	5,62	2,98	4,38	0,52	32,60	32,77	42,38	22,38	12,3
6	3,35	3,50	7,36	3,22	32,06	8,04	11,50	0,50	7,89
7	5,10	0,58	3,39	0,30	32,01	5,28	16,51	3,25	0,45

Tabla 15: Ejemplo de diagnósticos por zonas de “Carlswood” para diferentes recorridos.

6 CONCLUSIONES

Se diseñó y validó un Modelo de Diagnóstico de manejo erróneo. Este Modelo contempla la utilización de datos disponibles en la computadora del vehículo como variables de entrada, constituyéndolo como una solución no intrusiva al conductor.

Durante el proceso de validación del modelo, se han desarrollado diversos métodos que permiten la caracterización o clasificación de parámetros del conductor o la carretera, considerados como aportes innovadores dentro del estado del arte para sistemas de diagnóstico:

- Método de inversión, utilizado como técnica para calcular el desempeño de evolución
- Método de categorización de conductores (MCC), usado como técnica de caracterización de individuos de tal forma que puedan realizarse comparaciones entre ellos.
- Método de clasificación ponderado (MCP), técnica que permite clasificar zonas de riesgo de una carretera.

El análisis de los resultados obtenidos para cada uno de estos algoritmos y la comparación de los resultados permite concluir lo siguiente:

- Del análisis de resultados de los experimentos practicados durante esta investigación, y como resultado de la caracterización de los recorridos ejecutados sobre el simulador, se pudieron determinar los umbrales de decisión de cada caso. La definición de los umbrales mediante intervalos de confianza, permitió establecer en qué rango de valores se encuentra el porcentaje de interés estadístico de las muestras consideradas.
- Para *evolución* se determinaron dos umbrales de repeticiones necesarias para el aprendizaje humano: Un umbral en el que se asegura que el 83,3% de los individuos ya ha alcanzado su estado de *equilibrio* en el aprendizaje y otro en el que se asegura que el 83,3% tiene su recorrido de *transición* dentro del intervalo de confianza hallado. También

se pudo apreciar el proceso de aprendizaje humano al adquirir destreza en el manejo de un vehículo y se determinaron las etapas involucradas en el proceso. También se halló el número mínimo de sesiones de práctica que se requiere para garantizar un alto porcentaje de asimilación por parte de los aprendices de manejo. Los resultados validan la hipótesis planteada en 5.2.

- De manera análoga, para *adaptabilidad* se pudo observar que los conductores pasan por un nuevo ciclo de aprendizaje que requiere menos sesiones repetitivas para asimilar las nuevas variables, puesto que se inicia el proceso luego de haber completado el entrenamiento anterior. Se determinaron también dos umbrales de repeticiones necesarias para el aprendizaje adaptativo ante nuevas condiciones: Un umbral en el que se asegura que el 83,3% de individuos ya ha alcanzado su nivel de *estabilización* bajo las nuevas condiciones de manejo y otro umbral en el que se asegura que el 83,3% de individuos tiene su recorrido de *transición*, bajo el nuevo esquema, dentro del intervalo de confianza hallado.
- Al hacer *contraste* entre conductores se contempló que los conductores poseen características intrínsecas de manejo que no varían durante su proceso de aprendizaje y que por consiguiente los caracterizan. La diferenciación alcanzada, bajo las variables obtenidas del sistema de diagnóstico, no es absoluta y por consiguiente existen casos en los que no se puede determinar ninguna diferencia estadística apreciable cuando no hay *cualidades* comunes o cuando el desempeño en determinada *cualidad* es muy similar. Así, se definieron 2 conceptos: Un umbral correspondiente al valor máximo de diferencia del *desempeño* de las *cualidades* comunes entre los conductores para especificar que si hay diferencia apreciable en ese *aspecto específico*; y una condición para catalogar a dos conductores como radicalmente diferentes que consiste en aquellos casos en los que los conductores no poseen *cualidades* en común que puedan ser comparadas.
- Para las alteraciones de conciencia se logró cuantificar la incidencia de la distracción y el sueño en la pérdida del control del vehículo y se hallaron umbrales para determinar si una persona se encuentra bajo alguna de estas dos alteraciones contempladas en este estudio.

Se determinaron los aspectos específicos cuya información resulta más relevante para diagnosticar que el individuo está afectado por alguna de las alteraciones. Igualmente, se determinó el umbral de distracción y el de somnolencia para cada uno de los diagnósticos específicos. Aunque sólo se trabajaron dos alteraciones, los resultados reflejan que un análisis similar permitirá caracterizar las tres alteraciones de conciencia faltantes, robusteciendo aún más el clasificador.

- A pesar de usar un criterio subjetivo para la división de una pista en sus zonas de riesgo, el método MCP ofrece una alternativa confiable para analizar el *mapa de riesgo* de una carretera, cuantificando el nivel de peligrosidad de cada tramo.
- El Modelo de Diagnóstico propuesto en esta Tesis es susceptible a constituirse como una plataforma de respaldo a:
 - Las autoridades de tránsito, en cuanto a que se pueden centralizar y administrar las mediciones que se realizan en cada vehículo particular ejerciendo control preventivo y correctivo ante posibles infractores en las vías.
 - Entes reguladores de tránsito, al ofrecer una herramienta de medición para la toma de decisiones sobre el estado de una vía y la actualización de su señalización.
 - Academias de conducción, ofreciendo un simulador confiable con umbrales fijos establecidos, homologando y facilitando su labor mediante una evaluación cuantitativa.
 - Los conductores, en cuanto a que se convierte en una herramienta de registro tipo “caja negra” para ser usada como registro de históricos ante eventuales accidentes y posteriores reclamaciones.
 - Transportistas y dueños de vehículos, por tratarse de una solución de evaluación del desempeño de los conductores por contratar (acorde con mediciones de *adaptabilidad*) y de aquellos contratados (acorde con los resultados del registro histórico de diagnósticos).
 - Todos los anteriores, en cuanto a que los sistemas de señalización de vías pueden enlazarse con la central para actualizar las restricciones (límites de velocidad, precaución ante presencia de infractores, etc.) de una carretera en tiempo real

- Todos los anteriores, al ser usada como sistema de identificación y validación de conductores autorizados a acceder a determinado vehículo.

7 TRABAJO FUTURO

Aunque se ha validado un método para el diagnóstico de manejo erróneo, es posible robustecer el dataset aumentando el espacio muestral, previa clasificación del ejercicio de recolección de información según la información que resulta relevante para cada enfoque.

Otra oportunidad que ofrece esta Tesis es establecer umbrales para la calificación de tipos de conductores (bueno, medio, malo) para respaldar un eventual ejercicio de auditoría al servicio de transportistas y dueños de vehículos.

Además, es posible determinar un método objetivo para la división de una pista en sus zonas de riesgo. Con ello, se puede lograr una segmentación óptima de la carretera, en busca de determinar cuáles son sus zonas de riesgo y qué tan riesgosas resultan dentro de una escala global.

Finalmente, el reto más importante que plantea todo el trabajo realizado en la línea de Transportes Inteligentes del Grupo de Investigación en Robótica y Sistemas Inteligentes de Uninorte, es la implementación de este modelo y su simulador EDDSystem en una plataforma real que garantice:

- Captura de datos de la computadora del vehículo (ECU) a una alta tasa de muestreo.
- Desarrollo de un dispositivo de a bordo capaz de integrar la información de la ECU con una estampa proveniente de un receptor GPS.
- Envío de esta información Internet a través de una red que garantice alta cobertura y bajos costos de envío de datos.
- Desarrollo de una aplicación que interactúe con una base de datos, con el fin de proveer monitoreo en tiempo real y registro histórico de la información.
- Implementación de los algoritmos de diagnóstico del EDDSystem.
- Desarrollo de una aplicación de monitoreo que muestre los resultados procesados y los disponga para su futura interconexión a otras plataformas para vigilancia y regulación de las vías.

8 GLOSARIO

ABS: Antilock Break System

ACC: Adaptative Cruise Control

EBD: Electronic Breakforce Distribution

ECU: Electronic Computer Unit

EPS: Electronic Power Steering

ESP: Electronic Stability Program

MCC: Método de categorización de conductores

MCP: Método de clasificación ponderado

Aspectos Específicos: Hace referencia a propiedades de conducción inherentes a cada individuo, en las que se describe su capacidad de respetar determinadas reglas de conducción. Este sistema considera 5 aspectos para determinar en el desempeño del conductor: Mantenerse en el carril, no salirse de la carretera, no exceder los límites de velocidad, no ejecutar acciones bruscas en el manejo del timón y no hacer un mal uso de la combinación de pedales durante el recorrido de análisis.

Categoría: Clasificación asignada a cada conductor, usando las *etiquetas de categorización*, de acuerdo al MCC.

Cualidad: Aspecto(s) específico(s) de conducción de un individuo en el(los) que no se observa *evolución* conforme aumenta su experiencia en pista, y por tanto se constituye como una característica intrínseca del conductor.

Estado equilibrado: Se considera como la fase de aprendizaje en la que el individuo ya ha asimilado las condiciones impuestas por el simulador dentro de la evolución del conductor y por consiguiente se esperan obtener bajos diagnósticos de conducción errónea y además dichos valores deben encontrarse alrededor de un *nivel de estabilización*.

Estado Inicial: Se considera como la fase de aprendizaje en la que el individuo comienza a asimilar las condiciones impuestas por el simulador dentro de la evolución del conductor.

Etiqueta de categorización: Valor numérico asignado para cada *cualidad* con el objetivo de obtener la *categoría* que será asignada a cada conductor de acuerdo al MCC.

Evolución: Proceso de afinamiento de un conductor en búsqueda de la asimilación de las condiciones impuestas por el simulador. Si el individuo aprende, es decir si llega a un nivel de estabilización, se dice que el conductor evolucionó, de lo contrario no se presenta *evolución*.

Evolución de Desempeño: El promedio de todos los recorridos normalizados para un mismo conductor, sobre una misma carretera y un mismo vehículo.

Método de inversión: Técnica utilizada para calcular el *desempeño de evolución* dentro de un conjunto de recorridos normalizados, mitigando los efectos de falsos positivos y falsos negativos dentro, propios del *estado inicial* y el *estado equilibrado*, respectivamente. En ella se identifica el recorrido a partir de la cual el comportamiento de los resultados es totalmente opuesto a las muestras iniciales. Requiere que los valores se encuentren entre 0 y 1 para que la inversión de las muestras se realice bajo la fórmula: $f(x)=1-x$. Fue diseñado para efectos de este estudio con el objetivo de hallar el *recorrido de transición*, a partir del cual el conductor mejora su desempeño de manejo.

Método de categorización de conductores (MCC): Técnica de multi-clasificación binaria que fue diseñada para efectos de este estudio, usando las *cualidades* de los conductores como las variables binarias consideradas en la clasificación general del conductor; con el objetivo de organizar a los individuos de tal forma que puedan realizarse comparaciones entre ellos.

Método de clasificación ponderado (MCP): Técnica utilizada para ordenar elementos de un conjunto de acuerdo con una tabla de posiciones ponderada, es decir que se considera el número de veces que cada elemento se encontró en determinada posición del listado organizado, y el valor de ponderación que posee esa posición del listado. Este método fue diseñado para efectos de este estudio con el fin de hallar las zonas de alto riesgo de una pista y organizarlas en un mapa de acuerdo a su nivel de peligrosidad.

Nivel de estabilización: Porcentaje promedio alrededor del cual giran los diagnósticos de conducción errónea durante el *estado equilibrado*.

Recorrido de adaptación: Recorrido o repetición en el que un conductor con experiencia asimila nuevas condiciones impuestas por el simulador llegando a un *nivel de estabilización* bajo las nuevas condiciones impuestas.

Recorrido de inversión: Recorrido a partir del cual se aplican las restas del tipo “1-Diagnóstico_Normalizado”. Permite construir la tabla con todos los *desempeños de evolución* para hallar el *recorrido de transición*.

Recorrido de adaptación relativo: Igual al recorrido de transición relativo, pero aplicado en la adaptación de un conductor a nuevas condiciones del simulador después de haber *evolucionado*.

Recorrido de transición: Recorrido o repetición en el que determinado conductor pasa del *estado inicial* al *estado equilibrado*. Corresponde al *recorrido de inversión* cuyo *desempeño de evolución* exhibe un máximo local.

Recorrido de transición relativo: Corresponde a un máximo local que proporciona el análisis de los datos bajo el Método de Inversión, asociado al paso hacia un nivel de aprendizaje intermedio del individuo.

9 BIBLIOGRAFÍA

- [1] L. Montoro, F. Alonso, C. Esteban and F. Toledo, "Manual de seguridad vial: El factor humano," *Univ. Psychol. Bogotá (Colombia)*, vol. 1, pp. 87-88, 2002.
- [2] D. A. Pomerleau, "Neural networks for intelligent vehicles," in *Proceedings of IEEE Conf. on Intelligent Vehicles*, 1993, pp. 19-24.
- [3] J. H. Lemelson, "Motor vehicle performance monitor and method," 1996.
- [4] H. Kumamoto, M. Sudo, K. Tenmouku, O. Shimizu and A. Nakajima, "A cognitive simulator to animate group behavior of car drivers," in *Emerging Technologies and Factory Automation, 1993. Design and Operations of Intelligent Factories. Workshop Proceedings. IEEE 2nd International Workshop on*, 1993, pp. 112-118.
- [5] M. A. S. Kamal, Raisuddin, Wahyudi and R. Muhida, "Comprehensive driving behavior model for intelligent transportation systems," in *Computer and Communication Engineering, 2008. ICCCE 2008. International Conference on*, 2008, pp. 1233-1236.
- [6] R. Bishop, *Intelligent Vehicle Technology and Trends*. Artech House Norwood,, MA, USA, 2005.
- [7] A. D. Lattner, J. D. Gehrke, I. J. Timm and O. Herzog, "A knowledge-based approach to behavior decision in intelligent vehicles," in *Intelligent Vehicles Symposium, 2005. Proceedings. IEEE*, 2005, pp. 466-471.
- [8] Y. Dong, Z. Hu, K. Uchimura and N. Murayama, "Driver inattention monitoring system for intelligent vehicles: A review," in *Intelligent Vehicles Symposium, 2009 IEEE*, 2009, pp. 875-880.
- [9] J. Guldner, V. I. Utkin and J. Ackermann, "A sliding mode control approach to automatic car steering," in *American Control Conference, 1994*, 1994, pp. 1969-1973 vol.2.
- [10] P. H. Wewerinke, "Model analysis of adaptive car driving behavior," in *Systems, Man, and Cybernetics, 1996., IEEE International Conference on*, 1996, pp. 2558-2563 vol.4.
- [11] F. Jimenez, F. Aparicio and J. Paez, "Evaluation of in-vehicle dynamic speed assistance in Spain: algorithm and driver behaviour," *Intelligent Transport Systems, IET*, vol. 2, pp. 132-142, 2008.
- [12] Lingling Li, Yangzhou Chen and Zhenlong Li, "Yawning detection for monitoring driver fatigue based on two cameras," in *Intelligent Transportation Systems, 2009. ITSC '09. 12th International IEEE Conference on*, 2009, pp. 1-6.
- [13] T. Kumagai and M. Akamatsu, "Modeling and prediction of driving behavior," in *Proc. 2nd Int. Symp. Meas., Anal. and Model. Human Funct*, 2004, pp. 357.

- [14] N. Oliver and A. P. Pentland, "Graphical models for driver behavior recognition in a smartcar," in *Intelligent Vehicles Symposium, 2000. IV 2000. Proceedings of the IEEE*, 2000, pp. 7-12.
- [15] T. Kumagai, Y. Sakaguchi, M. Okuwa and M. Akamatsu, "Prediction of driving behavior through probabilistic inference," in *Proceedings of the Eighth International Conference on Engineering Applications of Neural Networks*, 2003, pp. 8-10.
- [16] J. Engstrom and T. Victor, "Real-time recognition of large-scale driving patterns," in *Intelligent Transportation Systems, 2001. Proceedings. 2001 IEEE*, 2001, pp. 1018-1023.
- [17] J. Healey and R. Picard, "Smartcar: Detecting driver stress," in *Pattern Recognition, 2000. Proceedings. 15th International Conference on*, 2000, pp. 218-221 vol. 4.
- [18] T. Steele, T. Cutmore, D. A. James and A. Rakotonirainy, "An investigation into peripheral physiological markers that predict monotony," in *Proc. Road Saf. Res., Policing Educ. Conf*, 2004, .
- [19] M. T. Mohan, T. Gandhi and J. McCall, "Looking-In and Looking-Out of a Vehicle: Computer-Vision-Based Enhanced Vehicle Safety," *Intelligent Transportation Systems, IEEE Transactions on*, vol. 8, pp. 108-120, 2007.
- [20] H. Takahashi, D. Ukishima, K. Kawamoto and K. Hirota, "A Study on Predicting Hazard Factors for Safe Driving," *Industrial Electronics, IEEE Transactions on*, vol. 54, pp. 781-789, 2007.
- [21] R. Grace, V. E. Byrne, D. M. Bierman, J. M. Legrand, D. Gricourt, B. Davis, J. Staszewski and B. Carnahan, "A drowsy driver detection system for heavy vehicles," in *Digital Avionics Systems Conference, 1998. Proceedings., 17th DASC. the AIAA/IEEE/SAE*, 2001, pp. I36/1-I36/8 vol. 2.
- [22] H. Erdogan, A. Ereil and H. Abut, "Experiments on decision fusion for driver recognition," *Advances for in-Vehicle and Mobile Systems*, pp. 1-9, 2007.
- [23] F. Wang and H. Qin, "A FPGA based driver drowsiness detecting system," in *Vehicular Electronics and Safety, 2005. IEEE International Conference on*, 2005, pp. 358-363.
- [24] H. L. Bloecher, J. Dickmann and M. Andres, "Automotive active safety & comfort functions using radar," in *Ultra-Wideband, 2009. ICUWB 2009. IEEE International Conference on*, 2009, pp. 490-494.
- [25] T. Vaa, M. Penttinen and I. Spyropoulou, "Intelligent transport systems and effects on road traffic accidents: state of the art," *Intelligent Transport Systems, IET*, vol. 1, pp. 81-88, 2007.

- [26] J. Parviainen, M. Kirkko-Jaakkola, P. Davidson, M. A. V. Lopez and J. Collin, "Doppler radar and MEMS gyro augmented DGPS for large vehicle navigation," in *Localization and GNSS (ICL-GNSS), 2011 International Conference on*, 2011, pp. 140-145.
- [27] C. Spahn and N. Suri, "Integration of Event and Time-Triggered Systems for X-by-wire applications," 2006.
- [28] I. Standard, "ISO 11898, 1993," 1993, .
- [29] A. Farahani, G. Latif-Shabgahi and F. Tajarrod, "On the priority problem of CAN protocol: A new idea," in *Education Technology and Computer (ICETC), 2010 2nd International Conference on*, 2010, pp. V2-500-V2-505.
- [30] Feng Luo, Zhiqi Chen, Juexiao Chen and Zechang Sun, "Research on FlexRay communication system," in *Vehicle Power and Propulsion Conference, 2008. VPPC '08. IEEE*, 2008, pp. 1-5.
- [31] M. Paulitsch and B. Hall, "FlexRay in aerospace and safety-sensitive systems," *Aerospace and Electronic Systems Magazine, IEEE*, vol. 23, pp. 4-13, 2008.
- [32] S. Yasunobu, "An intelligent controller based on fuzzy target acquired by reinforcement-learning," in *SICE-ICASE, 2006. International Joint Conference*, 2006, pp. 2451-2456.
- [33] T. H. Chang, C. S. Hsu, C. Wang and L. K. Yang, "Onboard measurement and warning module for irregular vehicle behavior," *Intelligent Transportation Systems, IEEE Transactions on*, vol. 9, pp. 501-513, 2008.
- [34] T. Michler, T. Ehlers and J. U. Varchmin, "Vehicle diagnosis-an application for autonomous driving," in *Intelligent Vehicles Symposium, 2000. IV 2000. Proceedings of the IEEE*, 2000, pp. 168-173.
- [35] M. Perrier and J. Kalwa, "Intelligent diagnosis for autonomous underwater vehicles using a neuro-symbolic system in a distributed architecture," in *Oceans 2005-Europe*, 2005, pp. 350-355 Vol. 1.
- [36] M. Bürger, A. Griesser, J. Michael and M. Walzl, "Intelligent Vehicle Technologies Expert Systems for Driver Assistance Systems," .
- [37] H. Guo, H. Cheng, Y. Wu, J. Ang, F. Tao, A. Venkatasubramanian, C. Kwek and L. Liow, "An automotive security system for anti-theft," in *Networks, 2009. ICN'09. Eighth International Conference on*, 2009, pp. 421-426.
- [38] Z. Liu and G. He, "Research on vehicle anti-theft and alarm system using facing recognition," in *Neural Networks and Brain, 2005. ICNN&B'05. International Conference on*, 2005, pp. 925-929.

- [39] Z. Liu and G. He, "A vehicle anti-theft and alarm system based on computer vision," in *Vehicular Electronics and Safety, 2005. IEEE International Conference on*, 2005, pp. 326-330.
- [40] P. Waltermann, "Modelling and control of the longitudinal and lateral dynamics of a series hybrid vehicle," in *Control Applications, 1996., Proceedings of the 1996 IEEE International Conference on*, 1996, pp. 191-198.
- [41] W. Hongyan, Z. Yunshan, Z. Boying and Q. Xiding, "Research on integrated control strategy of CVT for passenger cars," in *Vehicle Electronics Conference, 1999.(IVEC'99) Proceedings of the IEEE International*, 1999, pp. 401-405 vol. 1.
- [42] M. L. Schwall, J. C. Gerdes, B. Bäker and T. Forchert, "A probabilistic vehicle diagnostic system using multiple models," in *15th Innovative Applications of Artificial Intelligence Conference (IAAI 2003), Acapulco, Mexico*, 2003, pp. 123-128.
- [43] L. K. Chen and A. G. Ulsoy, "Identification of a driver steering model, and model uncertainty, from driving simulator data," *Journal of Dynamic Systems, Measurement, and Control*, vol. 123, pp. 623, 2001.
- [44] J. Forbes, T. Huang, K. Kanazawa and S. Russell, "The batmobile: Towards a bayesian automated taxi," in *International Joint Conference on Artificial Intelligence*, 1995, pp. 1878-1885.
- [45] A. Pentland and A. Liu, "Modeling and prediction of human behavior," *Neural Comput.*, vol. 11, pp. 229-242, 1999.
- [46] F. Moreno, F. Aparicio, W. Hernández and J. Paez, "A low-cost real-time FPGA solution for driver drowsiness detection," in *Industrial Electronics Society, 2003. IECON'03. the 29th Annual Conference of the IEEE*, 2003, pp. 1396-1401 Vol. 2.
- [47] J. C. McCall and M. M. Trivedi, "Driver Behavior and Situation Aware Brake Assistance for Intelligent Vehicles," *Proceedings of the IEEE*, vol. 95, pp. 374-387, 2007.
- [48] M. M. Trivedi, T. Gandhi and J. McCall, "Looking-in and looking-out of a vehicle: Selected investigations in computer vision based enhanced vehicle safety," in *Vehicular Electronics and Safety, 2005. IEEE International Conference on*, 2005, pp. 29-64.
- [49] H. Abut, H. Erdoğan, A. Erçil, A. B. Çürüklü, H. C. Koman, F. Tas, A. Ö. Argunşah, B. Akan, H. Karabalkan and E. Çökelek, "Data collection with" UYANIK": too much pain; but gains are coming," 2007.
- [50] N. Valayden, Y. Guinand, F. Bizouerne, S. Bouaziz and T. Maurin, "Control and validation of expert tasks for a collision avoidance system," in *Intelligent Vehicles Symposium, 1996., Proceedings of the 1996 IEEE*, 1996, pp. 369-372.

- [51] M. Chan, A. Herrera and B. Andre, "Detection of changes in driving behaviour using unsupervised learning," in *Systems, Man, and Cybernetics, 1994. 'Humans, Information and Technology'. 1994 IEEE International Conference on*, 1994, pp. 1979-1982 vol.2.
- [52] K. Chae, D. Kim, S. Jung, J. Choi and S. Jung, "Evidence collecting system from car black boxes," in *Consumer Communications and Networking Conference (CCNC), 2010 7th IEEE*, 2010, pp. 1-2.
- [53] M. del Brío and S. Molina, *Redes Neuronales y Sistemas Borrosos: Introducción Teórica y Práctica*. Ra-Ma, 1997.
- [54] R. O. Duda, P. E. Hart and D. G. Stork, *Pattern Classification*. Citeseer, 2001.
- [55] M. Quintero, O. López and J. Rúa, "Intelligent erratic driving diagnosis based on artificial neural networks," in *ANDESCON, 2010 IEEE*, 2010, pp. 1-6.
- [56] B. SILVA, D. P. B. RIVEROS and C. JARAMILLO, "Aplicación de la Lúdica en la Curva de Aprendizaje," *Scientia Et Técnica*, vol. 11, pp. 185-187, 2005.
- [57] M. Burgueño, J. García-Bastos and J. González-Buitrago, "Las curvas ROC en la evaluación de las pruebas diagnósticas," *Med. Clin.*, vol. 104, pp. 661-670, 1995.